

DOI: 10.19650/j.cnki.cjsi.J2514391

基于微波测振与时频域特征融合的控制阀故障诊断研究*

郝洪涛¹, 柳琳琪¹, 马小东¹, 彭志科^{1,2}, 熊玉勇²

(1. 宁夏大学机械工程学院 银川 750021; 2. 上海交通大学机械系统与振动全国重点实验室 上海 200240)

摘要:控制阀作为工业过程控制系统的关键执行器,其运行状态直接影响生产安全与产品质量。针对现有控制阀故障诊断方法存在的压力流量信号响应滞后、振动信号易受干扰以及特征信息挖掘不充分等问题,提出了一种基于微波测振与时频域特征融合的气动控制阀故障诊断方法。首先,采用微波测振技术实现控制阀阀杆振动信号的非接触式高精度采集,克服了传统接触式传感器的应用局限,阀杆振动能够更直接地反映阀芯、弹簧和密封件等关键部件的状态。其次,构建了多尺度时频域双通道特征融合的网络结构,在时域支路设计了多尺度一维卷积结合双向门控循环单元充分提取信号的时序动态特征;频域支路通过短时傅里叶变换将一维信号转换为二维时频谱图,利用多尺度二维卷积网络提取频谱纹理特征。引入通道注意力机制自适应学习特征重要性权重,并采用交叉注意力机制实现时频域特征的深度融合,充分挖掘不同模态的互补信息。实验在配备微波测振系统的气动控制阀故障模拟试验台上进行,实验结果表明,所提方法在故障模拟试验台上对 6 种工作状态的分类准确率达到 96.25%,与常见的深度学习模型相比表现出更优越的诊断性能;在 DAMADICS 平台的 11 种故障模式验证中,该方法取得了 99.24% 的平均分类准确率,证明了模型良好的泛化能力,为控制阀故障诊断提供了新的技术途径。

关键词:气动控制阀;微波测振;故障诊断;多尺度特征提取;注意力机制

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 control valves based on microwave vibration measurement and time-frequency domain feature fusion

Hao Hongtao¹, Liu Linqi¹, Ma Xiaodong¹, Peng Zhike^{1,2}, Xiong Yuyong²

(1. School of Mechanical Engineering, Ningxia University, Yinchuan 750021, China; 2. State Key Laboratory of Mechanical System and Vibration, Shanghai Jiao Tong University, Shanghai 200240, China)

Abstract: Control valves serve as critical actuators in industrial process control systems, and their operational status directly impacts production safety and product quality. Addressing the limitations of existing control valve fault diagnosis methods—such as delayed pressure and flow signal responses, susceptibility of vibration signals to interference, and inadequate extraction of characteristic information—this study proposes a fault diagnosis method for pneumatic control valves based on microwave vibration measurement and time-frequency domain feature fusion. First, microwave vibration measurement technology is employed to achieve non-contact, high-precision acquisition of control valve stem vibration signals, overcoming the application limitations of traditional contact-based sensors. Stem vibration can more directly reflect the status of critical components such as the valve core, spring, and seals. Second, a network structure with multi-scale time-frequency domain dual-channel feature fusion is constructed. In the time-domain branch, multi-scale one-dimensional convolutions combined with bidirectional gated recurrent units are designed to fully extract the temporal dynamic features of the signal. In the frequency-domain branch, short-time Fourier transforms are used to convert one-dimensional signals into two-dimensional time-frequency spectrograms, and multi-scale two-dimensional convolutional networks are employed to extract spectral texture features. A channel attention mechanism is introduced to adaptively learn feature importance weights, and a cross-attention mechanism is employed to achieve deep fusion of time-frequency domain features, fully leveraging complementary information across

收稿日期:2025-08-16 Received Date: 2025-08-16

* 基金项目:国家自然科学基金(52465014)、宁夏自然科学基金(2025AAC020022)项目资助

different modalities. Experiments were conducted on a pneumatic control valve fault simulation test bench equipped with a microwave vibration measurement system. The experimental results show that the proposed method achieves a classification accuracy of 96.25% for six operating states on the fault simulation test bench, demonstrating superior diagnostic performance compared to common deep learning models. In the validation of 11 fault modes on the DAMADICS platform, the method achieved an average classification accuracy of 99.24%, demonstrating the model's excellent generalization capability and providing a new technical approach for control valve fault diagnosis.

Keywords: pneumatic control valve; microwave vibration measurement; fault diagnosis; multi-scale feature extraction; attention mechanism

0 引 言

控制阀作为工业过程控制系统的关键执行器,广泛应用于石油化工、电力等流程工业,其运行状态直接影响生产安全和产品质量^[1-3]。长期工作在恶劣环境下易发生阀座腐蚀、阀塞卡滞等故障^[4-5],因此开展控制阀故障诊断技术研究具有重要意义^[6-7]。

现有控制阀故障诊断方法主要分为基于模型和数据驱动两类^[8]。基于模型的方法是通过建立控制阀的物理机理模型或数学模型来进行故障诊断的。Jameson等^[9]采用物理失效分析方法,建立失效模式机制及影响分析模型,提出关键部件的诊断策略。Han等^[10]提出了基于典型变量分析的气动控制阀故障检测方法,显著提高了故障检测率。控制阀系统涉及流体力学、热力学和机械动力学的复杂耦合,精确建模需要准确的系统参数和物理机理。实际运行中的磨损、腐蚀导致参数时变,加之模型不确定性使建模困难。因此,数据驱动方法凭借无需精确模型、能自适应学习非线性映射的优势得到广泛应用。

基于数据驱动的方法是通过采集的多种不同状态信号来进行故障诊断。Huang等^[11]提出卷积神经网络-长短期记忆网络(convolutional neural network-long short-term memory, CNN-LSTM)方法处理多变量时序,在田纳西-伊斯曼化工过程上得到验证。朱朋等^[12]提出数字孪生驱动的小波注意力迁移网络,解决了齿轮箱故障诊断中数据稀缺和模型泛化性差的问题。Sun等^[13]提出基于数学模型插补和改进深度残差收缩网络的控制阀故障诊断方法,有效处理缺失数据问题。Zhang等^[14]构建多路换向阀数字孪生(digital twin, DT)模型,采用域自适应 Wasserstein 生成对抗网络(domain adaptation-Wasserstein generative adversarial network, DA-WGAN)减小数据分布差异,结合一维卷积神经网络-门控循环单元-注意力机制(one-dimensional convolutional neural network-gated recurrent unit-attention, 1DCNN-GRU-Attention)实现高精度故障诊断。Shi等^[15]提出基于多传感器信息融合的液压换向阀故障诊断方法,采用熵权法加权多维特征并结

合卷积神经网络提取深度特征,有效降低了噪声环境下的诊断不确定性。Zhong等^[16]提出基于多传感器信息融合的半监督学习方法用于液压换向阀故障诊断,解决了实际工况下故障数据标注困难的问题。郭海科等^[17]提出基于动态校准残差网络和联合分布对齐机制的旋转机械跨工况故障诊断方法,在强噪声下具有较高的准确率。张帅印等^[18]提出融合海星优化算法(starfish optimization algorithm, SFOA)的变分模态分解(variational mode decomposition, VMD)与双向门控循环单元(bidirectional gated recurrent unit, BiGRU)的故障诊断方法,通过时域卷积网络(temporal convolutional network, TCN)提取深层特征,实现偏导射流伺服阀高精度故障识别。

然而,控制阀故障诊断的准确性很大程度上依赖于高质量的状态信号采集。目前,控制阀故障诊断主要依靠压力、流量和振动等信号进行分析。压力和流量信号虽然能够反映控制阀的宏观工作状态,但这些过程变量往往表现出较强的滞后性和非线性特征,且易受工况波动、管路特性等因素影响^[19-20]。而振动信号响应快、故障敏感性强,能直接反映内部机械部件状态。

现有研究多采用接触式加速度传感器安装在阀门出口法兰处采集振动信号,但主要反映的是阀体整体振动特性。阀体振动易受整体结构刚度、管道振动及流体脉动等外部干扰的影响,导致故障特征信息被稀释或掩盖。阀杆作为控制阀的重要运动部件,直接连接阀芯和执行机构,其振动直接反映了阀芯、弹簧和密封件等关键部件的状态^[21-22]。相比阀体振动信号,阀杆振动能够更直接地反映控制阀内部的动态过程。阀杆的高速往复运动特性使得传统接触式传感器难以直接安装和可靠测量,且接触式传感器的安装会增加阀杆的附加质量和机械负载^[23]。

近年来,微波测振技术作为一种新型的非接触式振动测量方法,凭借其非接触、精度高、观测距离远等优点,在桥梁结构、旋转机械等领域应用广泛^[23-25]。田文迪等^[26]基于微波全场测振技术,提出了桥梁轻量化监测方法,实现了多跨挠度与索力的非接触式同步测量。Niu等^[27]提出了一种耐高温谐振腔微波传感器,突破了现有微波传感器的温度限制,采用高阻抗补偿和双频相位补偿技术,实现1300℃环境下叶尖间隙的精确测量。研究

将微波测振技术应用于控制阀故障诊断领域,实现了阀杆振动信号的非接触式高精度采集。

尽管现有研究取得了显著进展,但仍存在以下4个方面的不足:1)状态信号采集的局限性,现有方法依赖响应滞后且易受干扰的压力流量信号,或仅采集阀体振动信号,未能直接获取包含更丰富故障信息的阀杆振动特征。2)特征提取单一化,多数方法仅从时域或频域单一角度提取特征,未能充分挖掘信号在不同域的互补信息;3)特征提取不充分,缺乏有效的多尺度特征提取机制;4)特征融合策略简单,多采用特征拼接或固定权重融合,未能自适应调整不同特征的重要性^[28-29]。

基于以上分析,本研究提出一种基于微波测振与多尺度时频特征融合的控制阀故障诊断方法。主要贡献包括:1)构建时频域双通道并行架构,同时从时域和频域两个模态挖掘信号的互补特征,并设计多尺度特征提取网络实现了时频双模态信息的深度挖掘;2)引入交叉注意力机制实现时频特征深度融合;3)通过通道注意力机制增强关键特征通道的权重,提升模型的特征表征能力;4)提出采用微波测振技术实现控制阀阀杆振动信号的非接触式采集,并在气动控制阀故障模拟平台和DAMADICS平台进行实验验证,全面衡量模型在不同数据集下的性能。

1 相关理论基础

1.1 微波测振原理

微波测振系统主要由微波收发模块、中频信号处理模块、数据采集系统和上位机分析系统4个核心模块构成,如图1所示。微波收发模块采用连续波调频体制,通过发射天线向被测目标发射连续微波信号,并通过接收天线接收目标反射信号。中频信号处理模块包括混频器、低噪声放大器、带通滤波器和正交解调器,负责将高频反射信号下变频至中频信号,并进行 I/Q 正交解调。数据采集模块对解调后的基带信号进行模数转换,确保能够准确捕获目标的振动信息。上位机分析系统完成振动参数提取和实时显示存储功能。

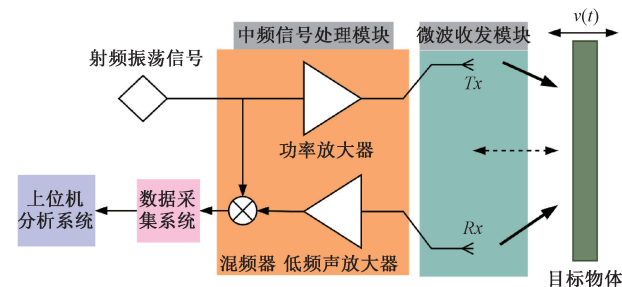


图1 微波测振的结构

Fig. 1 Structure of microwave vibration measurement

微波测振基于多普勒效应原理实现振动测量。设发射的连续波信号为:

$$s_t(t) = A_0 \cos(2\pi f_c t + \phi_0) \quad (1)$$

式中: A_0 为发射信号幅值; f_c 为载波频率; ϕ_0 为初始相位。当微波信号照射到以位移 $d(t) = d_0 + x(t)$ 运动的目标表面时(d_0 为静态距离, $x(t)$ 为振动位移),接收到的反射信号为:

$$s_r(t) = A_r \cos\left[2\pi f_c \left(t - \frac{2d(t)}{c}\right) + \phi_0\right] \quad (2)$$

将反射信号与本振信号混频并低通滤波后,得到基带信号,即:

$$s_b(t) = A_b \cos\left[\frac{4\pi f_c}{c} d(t) + \phi_n\right] = A_b \cos\left[\frac{4\pi}{\lambda} d(t) + \phi_n\right] \quad (3)$$

其中, $\lambda = c/f_c$ 为微波波长, c 为光速, ϕ_n 为相位噪声。通过 I/Q 正交解调获得,即:

$$\begin{cases} I(t) = A_b \cos\left[\frac{4\pi}{\lambda} d_0 + \frac{4\pi}{\lambda} x(t)\right] \\ Q(t) = A_b \sin\left[\frac{4\pi}{\lambda} d_0 + \frac{4\pi}{\lambda} x(t)\right] \end{cases} \quad (4)$$

利用反正切运算提取相位信息,即:

$$\phi(t) = \arctan\left[\frac{Q(t)}{I(t)}\right] = \frac{4\pi}{\lambda} d_0 + \frac{4\pi}{\lambda} x(t) \quad (5)$$

通过高通滤波去除直流分量 $\frac{4\pi}{\lambda} d_0$,并进行相位解缠绕处理,得到目标振动位移,即:

$$x(t) = \frac{\lambda}{4\pi} \Delta\phi(t) \quad (6)$$

对位移信号求导可获得振动速度 $v(t) = \dot{x}(t)$ 和振动加速度 $a(t) = \ddot{x}(t)$ 。

1.2 控制阀结构及测振合理性分析

气动控制阀基本结构如图2所示。它主要由执行机构和阀体两部分组成。执行机构包含气室、膜片及弹簧等核心部件,通过定位器接收控制信号并调节气源压力,驱动阀杆产生往复位移;阀体部分则包含填料、阀芯及阀座等组件,通过阀芯与阀座之间节流面积的变化来实现流体流量的调节。

阀杆是连接气动执行机构与内部阀芯的关键运动部件,处于控制阀动力传导的核心位置。执行机构内部的气室漏气、弹簧疲劳,以及阀体内部的阀芯磨损等引起系统内部状态改变的故障,其产生的异常振动特征会通过机械耦合直接反映在阀杆振动特征中。相比于容易受到管路流体脉动和环境噪声干扰的阀体振动信号,阀杆振动信号与内部故障的关联度更高,能够更直接地提取出反映控制阀健康状态的特征信息。




图2 气动控制阀结构

Fig. 2 Pneumatic control valve structure

1.3 BiGRU 神经网络

双向门控循环单元是一种改进的循环神经网络结构,通过结合门控循环单元(gated recurrent unit, GRU)和双向处理机制,能够有效捕获序列数据中的长期依赖关系和双向上下文信息。GRU 是一种简化的长短期记忆网络(long short-term memory, LSTM)变体,其网络如图3所示,通过引入重置门和更新门来控制信息流动。相比于 LSTM,GRU 具有更少的参数和更简单的结构,但仍能保持良好的性能。

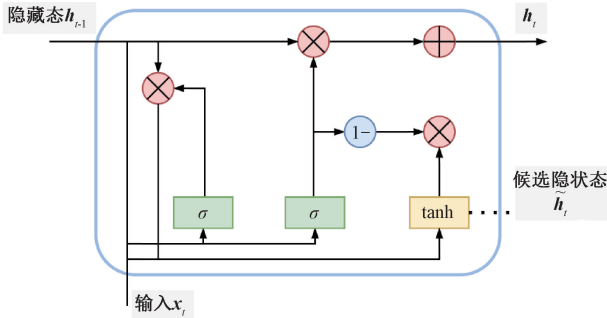


图3 GRU 网络结构

Fig. 3 GRU network structure

GRU 的核心计算过程可表示为:

$$\begin{cases} r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \\ z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \\ \tilde{h}_t = \tanh(W_h \cdot [r_t \odot h_{t-1}, x_t] + b_h) \\ h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \end{cases} \quad (7)$$

其中, r_t 为重置门, z_t 为更新门, \tilde{h}_t 为候选隐藏状态, h_t 为隐藏状态更新, σ 表示 sigmoid 激活函数, \odot 表示逐元素乘法, W_r 、 W_z 、 W_h 分别为重置门、更新门和候选状态的权重矩阵, b_r 、 b_z 、 b_h 为对应的偏置项, x_t 为时刻 t 的输入, h_t 为时刻 t 的隐藏状态。

BiGRU 包含两个独立的 GRU 层:前向 GRU 处理从序列开始到结束的信息,后向 GRU 处理从序列结束到开始的信息。对于时刻 t , BiGRU 的输出由两个方向的隐藏状态拼接而成,即:

$$\begin{cases} \vec{h}_t = \overrightarrow{GRU}(x_t, \vec{h}_{t-1}) \\ \overleftarrow{h}_t = \overleftarrow{GRU}(x_t, \overleftarrow{h}_{t+1}) \\ h_t = [\vec{h}_t; \overleftarrow{h}_t] \end{cases} \quad (8)$$

其中, \vec{h}_t 和 \overleftarrow{h}_t 分别表示前向和后向的隐藏状态, $[\ ;]$ 表示向量拼接操作。

1.4 基于 STFT 的时频表构建

短时傅里叶变换(short-time Fourier transform, STFT)是分析非平稳信号的重要时频分析方法。与传统傅里叶变换只能获得信号的全局频谱不同,STFT 通过在时域信号上滑动窗函数,将信号分解为一系列局部平稳段并分别进行傅里叶变换,从而获得信号随时间变化的频谱信息。

对于离散信号 $x[n]$, 其 STFT 定义为:

$$X[m, k] = \sum_{n=-\infty}^{+\infty} x[n] w[n - mR] e^{-j2\pi kn/N} \quad (9)$$

其中, m 为时间帧索引, k 为频率 bin 索引, R 为帧移, N 为 FFT 点数, $w[n]$ 为窗函数。文中采用汉宁窗作为窗函数,其表达式为:

$$w[n] = 0.5 - 0.5 \cos\left(\frac{2\pi n}{L-1}\right), \quad 0 \leq n \leq L-1 \quad (10)$$

其中, L 为窗长。

1.5 通道注意力机制

通道注意力机制是一种自适应特征重标定技术^[30],通过学习不同特征通道的重要性实现特征增强,如图4所示。




图4 通道注意力机制原理

Fig. 4 Principle of channel attention mechanism

研究采用压缩-激励(squeeze-and-excitation, SE)结构实现通道注意力机制。对于输入特征图 $X \in \mathbb{R}^{H \times W \times C}$, 其中 H 、 W 、 C 分别表示特征图的高度、宽度和通道数,通道注意力机制的计算过程包括压缩(squeeze)、激励(excitation)和乘积3个阶段。

在压缩阶段,通过全局平均池化将每个通道的空间信息压缩为一个标量,得到通道描述符,即:

$$z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j) \quad (11)$$

其中, $x_c(i, j)$ 表示第 c 通道在位置 (i, j) 处的特征值。

在激励阶段,通过两层全连接网络学习通道间的非线性依赖关系,即:

$$\begin{cases} s = \sigma(W_2 \delta(W_1 z)) \\ s' = \sigma(W_2 \delta(W_1 z')) \end{cases} \quad (12)$$

其中, $s \in R^{C \times 1}$ 为通道权重向量; $W_1 \in R^{\frac{C}{r} \times C}$ 和 $W_2 \in R^{\frac{C}{r} \times \frac{C}{r}}$ 为可学习参数, r 为缩减比例; δ 表示 ReLU 激活函数; σ 为 sigmoid 激活函数。最终的注意力权重通过融合两种池化方式的结果得到:

$$a = \sigma(s + s') \quad (13)$$

通道注意力的输出为原始特征图与注意力权重的逐通道乘积,即:

$$\tilde{x}_c = a_c \cdot x_c \quad (14)$$

1.6 交叉注意力机制

交叉注意力机制是深度学习中一种重要的特征交互技术,其核心思想在于通过建立不同特征表示之间的关联映射,实现信息的有效传递和融合。在多模态学习领域,交叉注意力机制能够捕获不同模态数据间的内在关联性,从而提升模型的代表学习能力,具体原理如图 5 所示。

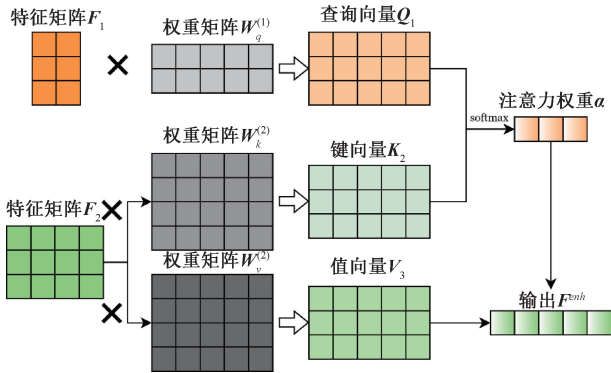


图 5 交叉注意力机制原理

Fig. 5 Principle of cross-attention mechanism

设原始信号通过方法 1 提取的特征矩阵为 $F_1 \in R^{d_1}$, 方法 2 提取的特征矩阵为 $F_2 \in R^{d_2}$, 其中 d_1 和 d_2 分别表示时域和频域特征的维度。交叉注意力机制的计算过程为:

1) 方法 1 对方法 2 的交叉注意力

(1) 线性变换

通过线性变换将 F_1 映射为查询向量(Query), F_2 映射为键向量(Key)和值向量(Value), 即:

$$\begin{cases} Q_1 = F_1 W_q^{(1)} \in R^{d_k} \\ K_2 = F_2 W_k^{(2)} \in R^{d_k} \\ V_3 = F_2 W_v^{(2)} \in R^{d_k} \end{cases} \quad (15)$$

其中, $W_q^{(1)} \in R^{d_1 \times d_k}$, $W_k^{(2)} \in R^{d_2 \times d_k}$ 和 $W_v^{(2)} \in R^{d_2 \times d_k}$ 为可学习的权重矩阵, d_k 为嵌入维度。

(2) 计算注意力权重

$$\alpha_{1 \rightarrow 2} = \text{softmax}\left(\frac{Q_1 K_2^T}{\sqrt{d_k}}\right) \quad (16)$$

(3) 输出

F_1 经 F_2 增强后的表示为:

$$F_1^{enh} = \alpha_{1 \rightarrow 2} V_3 \quad (17)$$

2) 方法 2 对方法 1 的交叉注意力

类似地, F_2 经 F_1 增强后的表示为:

$$F_2^{enh} = \alpha_{2 \rightarrow 1} V_1 \quad (18)$$

2 模型搭建

2.1 多尺度时域支路特征提取

时域支路负责从阀杆振动信号中提取时序特征, 采用多尺度卷积、通道注意力和 BiGRU 的级联结构, 如图 6 所示。针对不同故障特征尺度差异, 设计并行多尺度卷积, 采用 3、5、7 这 3 种大小不同的卷积核进行并行特征提取, 分别捕获局部瞬态和长时变化趋势。各分支输出 32 个特征通道, 经 ReLU 激活后拼接为 96 维特征。随后通过两层卷积网络深化特征提取, 每层

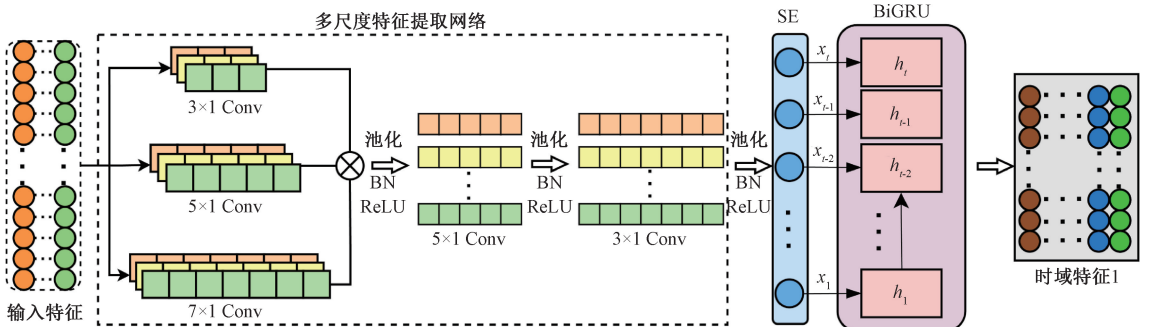


图 6 多尺度时域支路架构

Fig. 6 Multi-scale time domain branch architecture

配置批归一化和池化操作。引入通道注意力机制增强关键特征权重,增强模型对重要特征的选择性关注能力,最后经两层 BiGRU 捕获时序依赖关系,通过全连接层输出固定维度特征向量。该特征向量不仅保留了原始阀杆振动信号的时序动态特性,还融合了多尺度空间特征信息,为后续与频域特征的融合提供基础。

2.2 多尺度频域支路特征提取

频域支路通过 STFT 将一维振动信号转换为二维时

频谱图,从频域角度挖掘故障特征,如图 7 所示。采用 4 层具有不同卷积核的二维卷积网络提取时频纹理特征,每层配置批归一化和池化操作,最终通过全连接层输出与时域支路一致的维度。时频谱图能直观展示信号能量分布特性,不同故障类型表现出独特纹理模式,如阀杆卡滞在特定频带的周期性能量集中、阀门堵塞的高频成分异常等。这种转换将原本隐含的时域动态特征转化为可视化的频谱纹理特征,为故障诊断提供了更加丰富的特征表示。

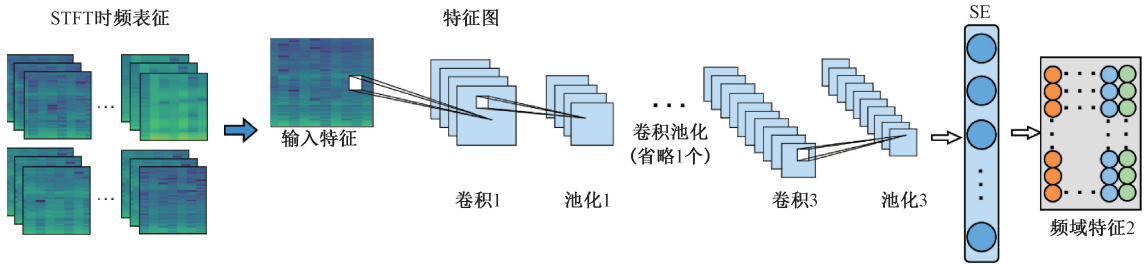


图7 多尺度频域支路架构

Fig. 7 Multi-scale frequency domain branch architecture

2.3 整体模型的构建

文中提出了一种多尺度时频域双通道特征融合网络模型,用于控制阀故障诊断,整体框架如图 8 所示。该网络由时域支路、频域支路、基于交叉注意力特征融合和故障分类 4 个模块组成。首先对原始信号数据进行预处理

理,在时域支路捕获阀杆振动信号的时序动态特征,在频域支路提取频谱纹理特征,然后经基于交叉注意力的特征融合模块实现时频特征的融合,充分挖掘了不同模态间的关联性,最后通过全连接层和 Softmax 函数完成故障分类。

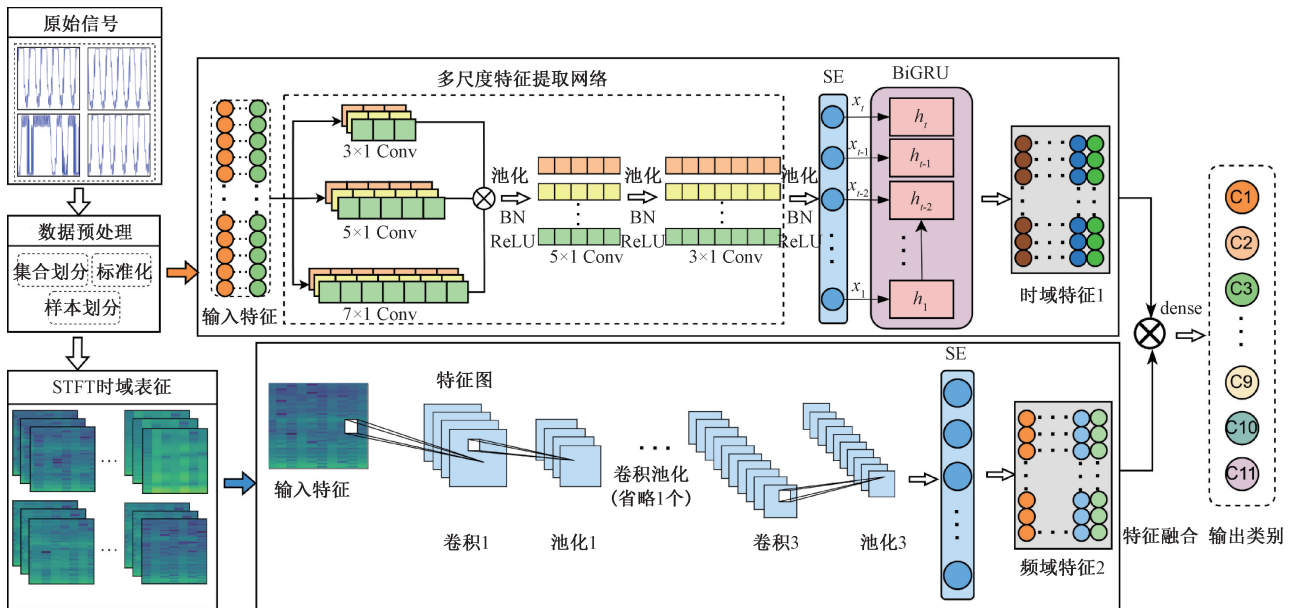


图8 多尺度时频域双通道特征融合模型架构

Fig. 8 Multi-scale time-frequency dual-channel feature fusion model architecture

3 实验验证与结果分析

为验证所提出的基于多尺度时频域双通道特征融合方法在控制阀故障诊断中的分类性能,首先在搭建的控制阀故障模拟试验台对模型进行验证,然后在 DAMADICS 平台上进行补充验证。通过两个不同来源的数据集验证,充分证明所提方法的有效性和泛化能力。

3.1 气动控制阀故障模拟试验台

为模拟真实工况下的控制阀故障数据,研究搭建了专门的控制阀故障模拟试验台。该试验台主要由 ATS 气动控制阀、供气管路系统、背压调节阀、数据采集系统以及上位机监控系统等组成,如图 9 所示。其中,ATS 气动控制阀采用气动薄膜执行机构,公称通径 DN100,行程 30 mm,可实现 0~100% 的开度调节。



图 9 控制阀故障模拟试验台

Fig. 9 Control valve failure simulation test bench

该试验台设计了 6 种典型的控制阀工作状态模拟: 1) 正常工作状态,控制阀按照设定信号正常动作;2) 传感器故障,通过调节阀门定位器反馈连杆机构的预紧力来模拟,使定位器接收到的阀位反馈信号与阀门实际开度之间出现偏差;3) 减压阀故障,调节供气压力使其偏离正常范围;4) 执行机构漏气故障,通过在气动管路中设置可控泄漏点实现;5) 阀杆摩擦力增大,采用可调节的机械装置增加阀杆运动阻力;6) 阀门卡滞故障,通过机械限位装置模拟阀门在特定位置的卡死现象。每种故障状态都可通过相应的方法进行控制和重现,确保实验数据的可靠性。

使用基于微波测振技术的微波位移传感器来采集阀杆振动信号,如图 9 所示,采样频率为 1 000 Hz。相比接触式加速度传感器,微波位移传感器具有 2 种显著优势: 1) 非接触测量方式避免了传感器与阀杆之间的机械磨

损,不会对阀门的正常运行产生额外负载;2) 测量距离远,适用于恶劣环境。

3.2 传感器布置与安装

为确保阀杆振动信号采集的精度,实验选用 MDS 系列微波位移传感器,并采用 DC12 V 稳压电源供电,如图 10 所示。传感器通过 1.5 m 长的屏蔽线连接至 PC 端,利用配套软件进行实时采集与管理。传感器固定在可调高度的三角支架上,放置于控制阀正前方,确保天线中心轴线与受测的不锈钢钢片保持垂直对准,测量距离设定在传感器的线性灵敏区内。




图 10 微波位移传感器的安装与布置

Fig. 10 Installation and placement of microwave displacement sensors

在实验布置中,针对控制阀阀杆呈细长圆柱状且表面反射特性不均的问题,实验引入了一种轻质、高刚性的不锈钢钢片作为振动传输介质。由于阀杆通常为无磁性的圆柱形结构,导致磁吸式加速度传感器无法吸附在其表面进行测量。该钢片通过机械连接牢固固定于阀杆中段,随阀杆同步进行往复运动,将阀杆原本纵向机械振动特征传递至钢片表面,从而将对曲面目标的测量转化为对平面的垂直位移测量,实现对阀杆动态响应的高保真采集。

3.3 参数设置

数据集按照 70%、15%、15% 的比例划分为训练集、验证集和测试集,三者之间无交集,以避免数据泄漏。所有输入数据采用 z-score 标准化处理,以消除量纲差异并提升模型收敛稳定性。每种工作状态连续采集 100 s,数据长度为 100 000,采用滑动窗口方法对原始阀杆振动信号进行分割,确保相邻样本间 50% 的重叠率以保持时序连续性。训练过程中,批次大小设为 32,训练轮数为 150 轮,采用 ReLU 激活函数,优化器选用 Adam,采用自适应学习率,初始学习率设为 0.001。

3.4 诊断结果与分析

混淆矩阵是评估分类模型性能的重要工具,通过将预测结果与真实标签进行对比,能够直观展示模型对各类别的识别能力和误分类模式。为了验证所提出的时频域双通道特征融合方法在控制阀故障诊断中的有效性,构建了6×6的混淆矩阵,如图11所示。

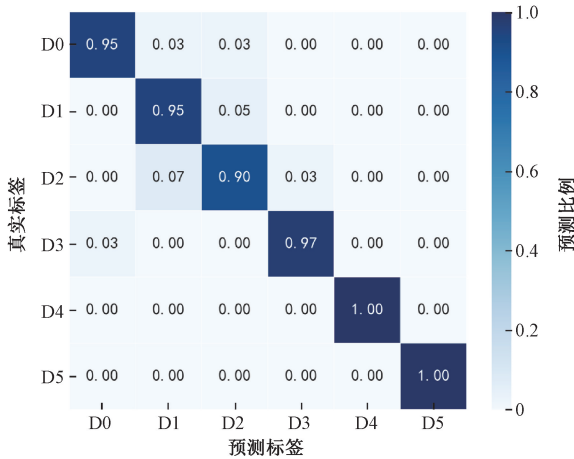


图11 测试集混淆矩阵

Fig. 11 Test set confusion matrix

该矩阵包含了正常状态(D0)以及传感器故障(D1)、减压阀故障(D2)、漏气故障(D3)、摩擦故障(D4)和卡滞故障(D5)等5种典型故障模式的分类结果。模型的平均分类准确率为96.25%,从混淆矩阵可以看出,标签D4和D5实现了精确识别,标签D0、D1、D2和D3存在不同程度的混淆情况,这一结果证明了所提模型能够有效提取控制阀的故障特征,表现出良好的分类能力。

从故障发生机理分析,D1、D2与D3之间存在较为明显的识别混淆,其原因在于这几类故障对阀杆运动状态的影响具有物理上的相似性。首先,在定位精度方面,D1由于反馈连杆松动导致信号感知偏差,而D2由于供气压力波动导致驱动力不稳。在闭环控制下,定位器为了修正这些偏差会频繁调整输出气压,使得阀杆产生相似的往复振荡特征,导致两者在时域波形上非常接近。其次,减压阀故障引起的供气压力不稳定,会直接导致阀杆在运动过程中出现迟滞或抖动,这种不稳定的位移表现与传感器反馈连杆松动引起的信号失真相似,从信号表征上增加了区分难度。此外,D2的供气不足与D3的气室漏气在本质上都造成了执行机构内部推力的下降,使得阀杆在克服弹簧力和填料摩擦力运动时,都表现出类似的频率特征和能量分布。综上,模型在提取这三类故障特征时容易产生混淆,增加了区分难度。

3.5 模型的评价指标

为全面评估模型在控制阀故障诊断中的性能表现,采用精度、召回率和F1-分数作为主要评价指标来衡量模型的分类效果,其表达式为:

$$Precision = \frac{TP}{TP + FP} \quad (19)$$

$$Recall = \frac{TP}{TP + FN} \quad (20)$$

$$F1-score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (21)$$

其中,TP表示真正例,FP表示假正例,FN表示假负例。

表1展示了模型在对6种控制阀工作状态的分类性能评价指标。从整体性能来看,模型的平均精度、召回率和F1-分数均达到96%以上,每个类别的各项指标都在90%以上,验证了模型在控制阀故障诊断任务中的良好的诊断性能。

表1 测试集分类效果评价指标

Table 1 Evaluation indicators for classification

| | | performance of the test set (%) | | |
|-------|----|---------------------------------|--------|--------|
| 工作状态 | 标签 | 精度 | 召回率 | F1-分数 |
| 正常 | D0 | 97.44 | 95.00 | 96.20 |
| 传感器故障 | D1 | 90.48 | 95.00 | 92.68 |
| 减压阀故障 | D2 | 92.31 | 90.00 | 91.14 |
| 漏气故障 | D3 | 97.50 | 97.50 | 97.50 |
| 摩擦故障 | D4 | 100.00 | 100.00 | 100.00 |
| 卡滞故障 | D5 | 100.00 | 100.00 | 100.00 |
| 平均 | | 96.29 | 96.25 | 96.25 |

3.6 分类效果可视化

采用t-SNE算法对模型提取的高维特征进行降维可视化,验证特征学习能力和空间可分性。t-SNE通过非线性映射保持数据局部结构,将高维特征投影至二维空间直观展示不同故障类别的聚类效果。图12展示了测试集样本经t-SNE降维后在二维平面上的分布情况,其中不同形状的散点代表6种不同的控制阀工作状态。

从图12的特征分布可以观察到6种工作状态形成了明显的聚类结构,表明模型成功学习到了各类别的判别性特征表示。D4和D5形成了独立且紧凑的聚类簇,这与其在混淆矩阵中表现出的精确分类性相一致。D0和D3同样呈现出良好的聚类特性,D1与D2存在少量重叠,从特征空间的展示了两类间存在误分类。t-SNE可视化结果表明,通过时域支路的多尺度特征提取和频域支路的时频纹理分析,结合交叉注意力机制的特征融合,

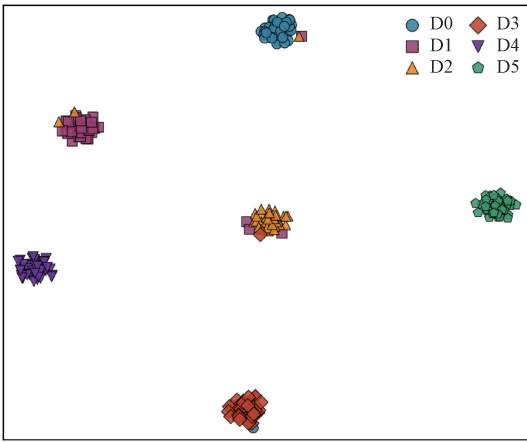


图 12 分类特征可视化

Fig. 12 Classification feature visualisation

模型能够将原始的高维阀杆振动信号映射到具有良好判别性的特征空间,实现了高精度的控制阀故障诊断。

3.7 性能对比与消融实验分析

1) 诊断精度对比分析

为验证所提出的时频域双通道特征融合方法的优越性,并探究模型内部组件对故障诊断结果的贡献,选取了经典深度学习模型与其他文献提到的 2 种优秀的模型进行对比实验,并进行了针对时域与频域支路的消融实验,对比结果如表 2 所示。在对比模型方面,选取了经典的空间特征提取模型卷积神经网络 (convolutional neural network, CNN)、典型的时序建模方法长短时记忆网络 (long short term memory, LSTM) 以及验证简单特征融合效果的 CNN-LSTM 组合模型;同时引入了基于交叉注意力机制的 CNN-BiTCN-CA 模型^[31]与结合残差网络和双向长短时记忆网络的 SE-ResNet-BiLSTM 模型^[32]。在消融实验部分,通过分别测试时域支路与频域支路在单独运行时的诊断表现,论证了时频域多尺度特征融合策略对提升诊断准确率的必要性。

表 2 模型性能对比及消融实验结果

Table 2 Diagnostic model performance comparison and ablation experiment results (%)

| 方法 | 准确率 | 精度 | 召回率 | F1-分数 |
|------------------|-------|-------|-------|-------|
| CNN | 75.00 | 75.20 | 75.01 | 75.05 |
| LSTM | 81.25 | 81.42 | 81.25 | 81.30 |
| CNN-LSTM | 86.67 | 87.02 | 86.66 | 86.75 |
| SE-ResNet-BiLSTM | 92.08 | 92.33 | 92.08 | 92.09 |
| CNN-BiTCN-CA | 92.92 | 93.20 | 92.90 | 92.93 |
| 时域支路 | 89.58 | 89.64 | 89.58 | 89.59 |
| 频域支路 | 82.92 | 83.38 | 82.91 | 83.01 |
| 本文方法 | 96.25 | 96.29 | 96.25 | 96.25 |

实验结果表明,传统单一模型 CNN 和 LSTM 的准确率分别为 75.00% 和 81.25%,性能相对有限。CNN-LSTM 组合模型准确率提升至 86.67%,但仍低于 90%。CNN-BiTCN-CA 和 SE-ResNet-BiLSTM 模型准确率分别为 92.08% 和 92.92%。所提模型取得 96.25% 的准确率,相比 CNN、LSTM、CNN-LSTM、CNN-BiTCN-CA 和 SE-ResNet-BiLSTM 分别提升了 21.25%、15%、9.58%、4.17% 和 3.33%。由表 2 的实验结果对比可知,所提出的模型表现出最优的评价指标,通过充分挖掘特征信息,实现了对控制阀故障类型的精准诊断。

通过消融实验来对比支路性能可以发现,时域支路单独使用的准确率 (89.58%) 高于频域支路 (82.92%),这表明阀杆振动信号中的时序动态特征包含了更多的故障判别信息。该方法通过多尺度特征提取与交叉注意力机制实现时频融合后,准确率相比时域和频域支路分别提升了 6.67% 和 13.33%,证明了时、频两个维度特征之间存在互补性,验证了所设计的时频域双通道架构对提高诊断性能的重要性。

2) 运行效率对比分析

为了评估所提模型的运行效率,在统一的硬件环境下,统计了各对比模型在迭代 150 轮过程中的训练耗时及模型参数量,具体结果如表 3 所示。

表 3 不同方法运行效率对比

Table 3 Comparison of operational efficiency among different methods

| 诊断模型 | 准确率/% | 参数量/ 10^6 | 训练时间/s |
|------------------|-------|-------------|--------|
| CNN | 75.00 | 0.85 | 112 |
| LSTM | 81.25 | 1.02 | 145 |
| CNN-LSTM | 86.67 | 1.78 | 247 |
| SE-ResNet-BiLSTM | 92.08 | 3.58 | 412 |
| CNN-BiTCN-CA | 92.92 | 2.12 | 328 |
| 本文方法 | 96.25 | 2.78 | 368 |

由表 3 可知,在取得 96.25% 诊断准确率的前提下,所提方法的模型参数量为 2.78×10^6 。由于采用了双通道特征融合架构,其参数规模相较于基础的 CNN、LSTM 及 CNN-LSTM 模型有所增加,且相较于 CNN-BiTCN-CA (2.12×10^6) 也有一定增加,但比 SE-ResNet-BiLSTM (3.58×10^6) 模型降低了 22.35%。所提方法虽需较高的计算资源,但所设计的时频域双通道架构是保障诊断精度的核心基础。在模型训练效率方面,所提方法的训练总耗时为 368 s,相较于 SE-ResNet-BiLSTM 展现出更优的收敛性能。综上所述,在保证合理计算负荷的同时,性能提升显著,体现了模型在复杂度与诊断性能间的平衡。

3.8 DAMADICS 平台数据集验证

1) DAMADICS 平台介绍

DAMADICS(development and application of methods for actuator diagnosis in industrial control systems)用于控制阀性能评估和故障检测研究。该平台通过精确的数学建模和物理仿真,模拟工业控制阀在多种工况下的动态行为,能够生成包含不同故障模式的阀杆振动信号数据,为故障诊断算法的开发和验证提供可靠支持。

采用基于 DAMADICS 平台生成的控制阀阀杆振动仿真数据,共选取表 4 中 11 类不同的故障模式,这些故障模式包括控制阀故障、定位器故障、马达故障等实际工业场景中的常见失效形式,充分反映了控制阀故障的多样性和复杂性。每种故障都会导致阀杆振动信号呈现独特的时域波动和频域分布特征,为研究的方法提供了可靠的实验验证基础。

表 4 数据集故障描述
Table 4 Dataset failure descriptions

| 标签 | 故障名称 | 故障特性 | 一般形成原因 |
|-----|---------|------|-------------|
| C0 | 阀门堵塞 | 突变 | 阻塞伺服马达阀杆移动 |
| C1 | 衬套摩擦增加 | 缓慢发展 | 机械磨损、沉积等 |
| C2 | 介质蒸发 | 突变 | 介质在阀门中蒸发 |
| C3 | 接头漏气 | 缓慢发展 | 机械振动导致螺丝松动等 |
| C4 | 膜片穿孔 | 突变 | 隔膜材料磨损等 |
| C5 | 弹簧失效 | 突变 | 弹簧材料疲劳或腐蚀 |
| C6 | 转换器故障 | 突变 | 转换器机械部件故障 |
| C7 | 位移传感器故障 | 突变 | 传感器机械部件故障 |
| C8 | 定位器反馈故障 | 突变 | 机械杆反馈系统异常等 |
| C9 | 供气压力下降 | 快变 | 供气站故障等 |
| C10 | 意外压力变化 | 快变 | 外部因素 |

2) 实验结果分析

为验证所提出模型的故障诊断的有效性与泛化能力,该研究在 DAMADICS 平台数据集上进行了测试验证。图 13 展示了所提模型在测试集上的混淆矩阵,模型的平均分类准确率达到 99.24%。从混淆矩阵可以观察到,11 种故障模式中有 8 种实现了精确识别,仅有标签 C0、C1 和 C8 存在少量误分类。对角线上呈现出清晰的深色带状分布,证明了模型不仅在实验室环境下表现优异,在工业场景下同样具有可靠的故障诊断能力。

表 5 详细列出了模型对 11 种故障模式的分类性能评价指标,所有故障模式的精度、召回率和 $F1$ -分数均超过 94%,各项指标的平均值均达到 99% 以上。对比自建试验台的实验结果,DAMADICS 数据集上的性能指标普

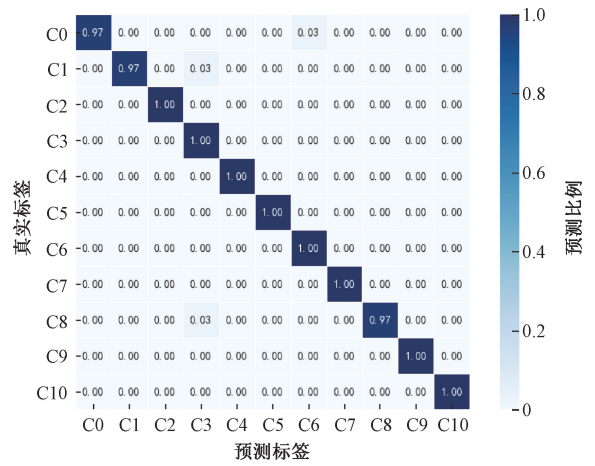


图 13 测试集混淆矩阵

Fig. 13 Test set confusion matrix

遍更高,这主要是由于自建试验台在实际物理环境中不可避免地存在环境噪声、机械振动以及传感器测量误差等干扰因素,而仿真平台能够提供相对纯净的信号条件。实验结果证明了模型在故障诊断任务中的良好分类性能与稳定性。

表 5 测试集分类效果评价指标
Table 5 Evaluation indicators for classification performance of the test set (%)

| 标签 | 精度 | 召回率 | $F1$ -分数 |
|-----|--------|--------|----------|
| C0 | 100.00 | 97.22 | 98.59 |
| C1 | 100.00 | 97.22 | 98.59 |
| C2 | 100.00 | 100.00 | 100.00 |
| C3 | 94.74 | 100.00 | 97.30 |
| C4 | 100.00 | 100.00 | 100.00 |
| C5 | 100.00 | 100.00 | 100.00 |
| C6 | 97.30 | 100.00 | 98.63 |
| C7 | 100.00 | 100.00 | 100.00 |
| C8 | 100.00 | 97.22 | 98.59 |
| C9 | 100.00 | 100.00 | 100.00 |
| C10 | 100.00 | 100.00 | 100.00 |
| 平均 | 99.28 | 99.24 | 99.25 |

为进一步验证模型在 DAMADICS 数据集上的特征学习效果,图 14 展示了 11 种故障模式经 t-SNE 降维后在二维特征空间的分布情况。从原始信号数据特征图可以观察到,故障样本在特征空间中分布较为分散,类别间边界模糊。经过时域支路处理后,多尺度卷积和双向 GRU 网络有效提取了阀杆振动信号的时序动态特征,使得部分故障类别开始呈现聚集趋势,但仍存在一定程度

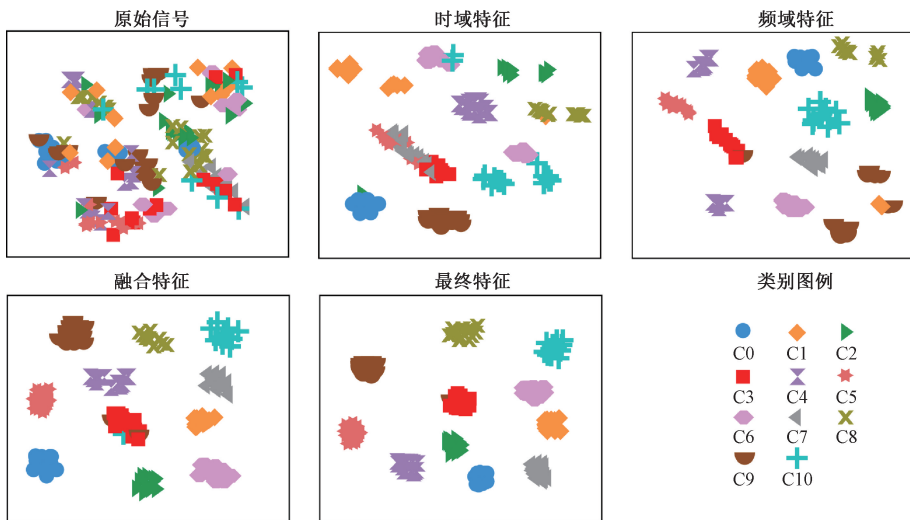


图 14 多层次 t-SNE 特征可视化

Fig. 14 Multi-level t-SNE feature visualization

的类间混叠。频域支路通过 STFT 变换和卷积处理,捕获信号的频域信息,部分故障模式呈现出与时域特征互补的特征分布,相比时域特征展现出的聚类模式,部分在时域中难以区分的故障类别在频域空间中表现出更明显的分离趋势,验证了模型能够从时频域分别提取互补的故障特征信息。

融合特征图表明,交叉注意力机制能够有效利用时频两支路的互补特征,显著提高了类间分离度,减少了重叠区域,体现了基于交叉注意力特征融合的优势。最终特征图进一步优化了聚类效果,各类别分布更加紧凑且边界清晰,仅有少数类别存在重叠,证明了模型在提升故障诊断性能方面的有效性。

4 结 论

针对控制阀故障诊断中特征提取单一、信息挖掘不充分的问题,提出了一种基于微波测振与时频域特征融合的故障诊断方法,主要工作和结论为:

1) 构建了基于多尺度时频域双通道特征融合的故障诊断模型。设计时域和频域双支路并行网络架构,时域支路采用多尺度一维卷积核提取不同感受野的局部特征,结合 BiGRU 网络捕获时序依赖关系;频域支路通过 STFT 将振动信号转换为时频谱图,利用多尺度二维卷积网络提取频谱纹理特征。引入通道注意力机制自适应调整特征权重,并采用交叉注意力机制实现时频域特征的深度融合,充分挖掘了多模态互补信息。

2) 搭建了气动控制阀故障模拟试验台,通过调节气压压力、阀杆摩擦力等关键参数,模拟了阀杆卡滞、执行机构漏气等 5 种典型故障。创新性地将微波测振技术应用于控制阀故障诊断领域,采用微波位移传感器实现了阀杆振动信号的非接触式采集,有效避免了接触式测量对阀杆运动特性的干扰,保证了故障信号的真实性和测量精度,为模型训练和验证提供了可靠的数据支撑。

3) 在控制阀故障模拟试验台上验证了所提方法的有效性。实验结果表明,该方法实现了 96.25% 的平均诊断准确率,平均精度、召回率和 $F1$ -分数均达到 96% 以上,相比 CNN、LSTM 和 CNN-LSTM 方法分别提升了 21.25%、15% 和 9.58%。消融实验证实了时频特征融合机制对模型性能提升的重要作用,t-SNE 可视化结果进一步显示,融合后的特征具有更清晰的类别边界和更好的聚类效果。此外,对比运行效率表明,在显著提升诊断精度的同时,将模型参数量控制在 2.78×10^6 ,训练总耗时为 368 s,证明了该架构在维持合理计算负荷的前提下,通过深度挖掘时频域互补特征,实现了计算开销与诊断可靠性的有效协调。

4) 在 DAMADICS 平台上进一步验证了模型的泛化能力。针对该平台的控制阀、执行机构、阀门定位器等 11 种故障模式,所提方法取得了 99.24% 的平均分类准确率,8 种故障模式实现了精确识别,平均精度、召回率和 $F1$ -分数均超过 99%。实验结果证明,该模型表现出优异的诊断性能,具有良好的泛化能力和工程应用价值。

参考文献

- [1] 彭娉, 陈时健, 任利杰, 等. 三偏心蝶阀密封面在位测量的点云数据处理方法[J]. 仪器仪表学报, 2021, 42(12): 30-38.
- PENG P, CHEN SH J, REN L J, et al. A point cloud data processing method for in-position measurement of sealing surface of triple eccentric butterfly valves [J]. Chinese Journal of Scientific Instrument, 2021, 42(12): 30-38.
- [2] XU B, SHEN J, LIU SH H, et al. Research and development of electro-hydraulic control valves oriented to industry 4.0: A review[J]. Chinese Journal of Mechanical Engineering, 2020, 33(2): 13-32.
- [3] 田祖织, 凡镛瑞, 郭阳阳, 等. 基于温度反馈的高速开关阀变电压驱动控制方法研究[J]. 仪器仪表学报, 2025, 46(3): 261-273.
- TIAN Z ZH, FAN R R, GUO Y Y, et al. Research on variable voltage drive control method for high-speed on/off valve considering temperature feedback [J]. Chinese Journal of Scientific Instrument, 2025, 46(3): 261-273.
- [4] 刘秀梅, 马雪敏, 李贝贝, 等. 调节阀空蚀-冲蚀耦合磨损的仿真及实验研究[J]. 华南理工大学学报(自然科学版), 2024, 52(12): 109-118.
- LIU X M, MA X M, LI B B, et al. Simulated and experimental investigation into coupled wear of cavitation and erosion in regulating valves [J]. Journal of South China University of Technology (Natural Science Edition), 2024, 52(12): 109-118.
- [5] 钱小毅, 王利鑫, 姜兴宇, 等. 基于交互监测与连通性模型的化工过程故障传播分析[J]. 化工学报, 2025, 76(8): 4155-4164.
- QIAN X Y, WANG L X, JIANG X Y, et al. Fault propagation analysis of chemical process based on interactive monitoring and connectivity model [J]. CIESC Journal, 2025, 76(8): 4155-4164.
- [6] CHAO Q, XU Z, SHAO Y CH, et al. Hybrid model-driven and data-driven approach for the health assessment of axial piston pumps [J]. International Journal of Hydromechatronics, 2023, 6(1): 76-92.
- [7] KORDESTANI M, SAIF M, ORCHARD M E, et al. Failure prognosis and applications – a survey of recent literature [J]. IEEE Transactions on Reliability, 2019, 70(2): 728-748.
- [8] 胡明辉, 高金吉, 江志农, 等. 航空发动机振动监测与故障诊断技术研究进展[J]. 航空学报, 2024, 45(4): 7-35.
- HU M H, GAO J J, JIANG ZH N, et al. Research progress on vibration monitoring and fault diagnosis for aero-engine [J]. Acta Aeronautica et Astronautica Sinica, 2024, 45(4): 7-35.
- [9] JAMESON N J, AZARIAN M H, PECHT M. Fault diagnostic opportunities for solenoid operated valves using physics-of-failure analysis [C]. 2014 IEEE International Conference on Prognostics and Health Management, 2014: 1-6.
- [10] HAN X J, JIANG J, XU AI D, et al. Fault detection of pneumatic control valves based on canonical variate analysis [J]. IEEE Sensors Journal, 2021, 21(12): 13603-13615.
- [11] HUANG T, ZHANG Q, TANG X AN, et al. A novel fault diagnosis method based on CNN and LSTM and its application in fault diagnosis for complex systems [J]. Artificial Intelligence Review, 2022, 55(2): 1289-1315.
- [12] 朱朋, 邓蕾, 汤宝平, 等. 数字孪生驱动小波注意力迁移网络的齿轮箱故障诊断方法[J]. 仪器仪表学报, 2025, 46(10): 86-95.
- ZHU P, DENG L, TANG B P, et al. Digital twin driven wavelet attention transfer network for gearbox fault diagnosis [J]. Chinese Journal of Scientific Instrument, 2025, 46(10): 86-95.
- [13] SUN F, XU H, ZHAO Y H, et al. Data-driven fault diagnosis of control valve with missing data based on modeling and deep residual shrinkage network [J]. Journal of Zhejiang University-Science A, 2022, 23(4): 303-314.
- [14] ZHANG G CH, ZHANG K, SHEN W, et al. Intelligent fault diagnosis of multi-way directional valves in hydraulic systems using digital twin and deep learning approaches [J]. Mechanical Systems and Signal Processing, 2025, 230: 112579.
- [15] SHI J CH, REN Y, TANG H SH, et al. Hydraulic directional valve fault diagnosis using a weighted adaptive fusion of multi-dimensional features of a multi-sensor [J]. Journal of Zhejiang University-Science A, 2022, 23(4):

- 257-272.
- [16] ZHONG Q, XU EN G, SHI Y, et al. Fault diagnosis of the hydraulic valve using a novel semi-supervised learning method based on multi-sensor information fusion [J]. *Mechanical Systems and Signal Processing*, 2023, 189: 110093.
- [17] 郭海科, 赵小强. 采用动态校准与联合分布对齐的旋转机械跨工况故障诊断[J]. *仪器仪表学报*, 2024, 45(8): 32-44.
- GUO H K, ZHAO X Q. Rotating machinery fault diagnosis across working conditions using dynamic calibration and joint distribution alignment [J]. *Chinese Journal of Scientific Instrument*, 2024, 45(8): 32-44.
- [18] 张帅印, 陶建峰, 吴兆宇, 等. 基于变分模态分解和双向门控循环单元的偏导射流伺服阀故障诊断[J]. *液压与气动*, 2025, 49(8): 1-11.
- ZHANG SH Y, TAO J F, WU ZH Y, et al. Fault diagnosis of deflector jet servo valve based on variational mode decomposition and bidirectional gated recurrent unit [J]. *Chinese Hydraulics & Pneumatics*, 2025, 49(8): 1-11.
- [19] JEONG E, YANG J H, LIM S C. Deep neural network for valve fault diagnosis integrating multivariate time-series sensor data [J]. *Actuators*, 2025, 14(2): 70.
- [20] SHANG L Y, ZHANG Y Y, ZHANG H Y. Valve stiction detection method based on dynamic slow feature analysis and Hurst exponent [J]. *Processes*, 2023, 11(7): 1913.
- [21] VENKATA S K, RAO S. Fault detection of a flow control valve using vibration analysis and support vector machine [J]. *Electronics*, 2019, 8(10): 1062.
- [22] YANG L X, LI SH X, HOU J J. Flow-induced vibration stability in pilot-operated control valves with nonlinear fluid-structure interaction analysis [J]. *Actuators*, 2025, 14(8): 372.
- [23] 熊玉勇, 李松旭, 彭志科. 基于微波感知的挠性结构动态响应监测 [J]. *振动与冲击*, 2020, 39(15): 278-282.
- XIONG Y Y, LI S X, PENG ZH K. Dynamic response monitoring of flexible structures based on microwave sensing [J]. *Journal of Vibration and Shock*, 2020, 39(15): 278-282.
- [24] LI S X, XIONG Y Y, WU G Y, et al. Microwave vibrometry: Noncontact vibration and deformation measurement using radio signals [J]. *IEEE Instrumentation & Measurement Magazine*, 2022, 25(2): 16-26.
- [25] 晏班夫, 欧阳康, 梁才. 桥梁工程中非接触位移测量技术研究综述 [J]. *交通运输工程学报*, 2024, 24(1): 43-67.
- YAN B F, OUYANG K, LIANG C. Research review on non-contact displacement measurement technology in bridge engineering [J]. *Journal of Traffic and Transportation Engineering*, 2024, 24(1): 43-67.
- [26] 田文迪, 熊玉勇, 吴朔阳, 等. 基于微波全场测振的桥梁轻量化监测技术 [J]. *振动与冲击*, 2025, 44(10): 106-115.
- TIAN W D, XIONG Y Y, WU SH Y, et al. Lightweight monitoring technology for bridges based on microwave full-field vibration sensing [J]. *Journal of Vibration and Shock*, 2025, 44(10): 106-115.
- [27] NIU G Y, LI SH, FU X, et al. A novel resonator cavity microwave sensor for high-temperature blade tip clearance measurement [J]. *Measurement*, 2024, 234: 114798.
- [28] 王雪纯, 李想, 杨随先. 基于 MCNN-MSA-BiGRU 的轴承故障诊断 [J]. *科学技术与工程*, 2025, 25(11): 4534-4542.
- WANG X CH, LI X, YANG S X. Bearing fault diagnosis based on MCNN-MSA-BiGRU [J]. *Science Technology and Engineering*, 2025, 25(11): 4534-4542.
- [29] 郝洪涛, 王凯, 张炳建, 等. 多尺度特征自适应融合的气动控制阀故障诊断 [J]. *仪器仪表学报*, 2023, 44(10): 168-178.
- HAO H T, WANG K, ZHANG B J, et al. Fault diagnosis of pneumatic control valves with multi-scale features adaptive fusion [J]. *Chinese Journal of Scientific Instrument*, 2023, 44(10): 168-178.
- [30] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2018: 7132-7141.
- [31] 赵国超, 刘崇德, 宋宇宁, 等. 基于特征交叉注意力机制融合的轴承故障诊断方法 [J]. *振动与冲击*, 2025, 44(12): 228-237.
- ZHAO G CH, LIU CH D, SONG Y N, et al. Bearing fault diagnosis method based on fusion of time-frequency features by cross-attention mechanism [J]. *Journal of*

Vibration and Shock, 2025, 44(12): 228-237.

- [32] 郁万康, 冷子文, 高军伟, 等. 基于改进 SE-ResNet-BiLSTM 的航空发动机中介轴承故障诊断[J]. 空军工程大学学报, 2024, 25(6): 35-42.

YU W K, LENG Z W, GAO J W, et al. A fault diagnosis for inter-shaft bearing of aero-engine based on improved SE-ResNet-BiLSTM [J]. Journal of Air Force Engineering University, 2024, 25(6): 35-42.

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, his M. Sc. and Ph. D. degrees 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.



柳琳琪, 2024 年于山东理工大学获得学士学位, 现为宁夏大学硕士研究生, 主要研究方向为机电设备智能运维与故障诊断。

E-mail: liulinqi567@163.com

Liu Linqi received his B. Sc. degree from Shandong University of Technology in 2024.

He is currently pursuing his master's degree at Ningxia University. His main research interests include intelligent operation and maintenance and fault diagnosis of electromechanical equipment.



熊玉勇, 2011 年于郑州大学获得学士学位, 2014 年于华中科技大学获熊得硕士学位, 2018 年于上海交通大学获得博士学位, 现为上海交通大学副教授, 主要研究方向为微波振动监测与智能感知。

E-mail: yy.xiong@sjtu.edu.cn

Xiong Yuyong received his B. Sc. degree from Zhengzhou University in 2011, his M. Sc. degree from Huazhong University of Science and Technology in 2014, and his Ph. D. degree from Shanghai Jiao Tong University in 2018. He is currently an associate professor at Shanghai Jiao Tong University. His main research interests include microwave vibration monitoring and intelligent sensing.