



中国科技期刊卓越行动计划项目入选期刊

# 控制与决策

CONTROL AND DECISION



## 基于多传感器数据融合的SA-DACNN齿轮箱故障诊断方法

张亚洲, 赵小强, 惠永永, 陈鹏

引用本文:

张亚洲, 赵小强, 惠永永, 陈鹏. 基于多传感器数据融合的SA-DACNN齿轮箱故障诊断方法[J]. *控制与决策*, 2024, 39(11): 3699–3708.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2023.1367>

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 基于Fisher Score与最大信息系数的齿轮箱故障特征选择方法

Fault feature selection method of gearbox based on Fisher Score and maximum information coefficient

*控制与决策*. 2021, 36(9): 2234–2240 <https://doi.org/10.13195/j.kzyjc.2019.1770>

#### 基于多块信息提取的AUV资源勘查系统故障检测

Fault detection of AUV resource exploration system based on multi-block information extraction

*控制与决策*. 2021, 36(4): 790–800 <https://doi.org/10.13195/j.kzyjc.2019.0732>

#### 小样本下多稀疏表示分类器的决策融合方法

Decision fusion of multiple sparse representation-based classifiers in case of small samples

*控制与决策*. 2021, 36(8): 1984–1990 <https://doi.org/10.13195/j.kzyjc.2019.1839>

#### 标签Petri网的路径信息在故障诊断中的应用

Application of path information of labeled Petri nets in fault diagnosis

*控制与决策*. 2021, 36(2): 325–334 <https://doi.org/10.13195/j.kzyjc.2019.0698>

#### 含混合储能的互联电力系统传感器容错负荷频率控制

Sensor fault-tolerant load frequency control for multi-area interconnected power system with hybrid energy storage system

*控制与决策*. 2021, 36(5): 1069–1077 <https://doi.org/10.13195/j.kzyjc.2019.1432>

# 基于多传感器数据融合的SA-DACNN齿轮箱故障诊断方法

张亚洲<sup>1,2</sup>, 赵小强<sup>1,2†</sup>, 惠永永<sup>1,2</sup>, 陈鹏<sup>3</sup>

(1. 兰州理工大学 电气工程与信息工程学院, 兰州 730050;

2. 甘肃省工业过程先进控制重点实验室, 兰州 730050;

3. 兰州石化职业技术大学 电子电气工程学院, 兰州 730050)

**摘要:** 针对单一传感器数据易受自身品质和环境的影响导致难以监控齿轮箱整体运行状况的问题, 提出一种基于多传感器数据融合的 SA-DACNN (self attention-dynamic adaptive convolutional neural network) 齿轮箱故障诊断方法. 首先, 将采集到的不同位置的传感器信号作为多通道信号, 并将多通道信号同时作为网络输入; 然后, 设计一种多通道特征融合模块, 该模块通过自适应地加权不同通道的信息, 确保不同通道的重要信息能够有效地融合, 解决特征级多通道数据融合问题; 最后, 在全连接层之前, 使用带残差连接的自注意力模块, 帮助网络自动学习全局信息, 增强对原始振动信号的特征学习能力. 在两个齿轮箱数据集上进行实验, 结果表明, 所提出方法具有较高的故障诊断准确率, 可以满足多传感器数据融合故障诊断的任务.

**关键词:** 故障诊断; 多传感器数据; 数据融合; 齿轮箱; 卷积神经网络; 自注意力

中图分类号: TH133.3; TP206.3

文献标志码: A

DOI: 10.13195/j.kzyjc.2023.1367

**引用格式:** 张亚洲, 赵小强, 惠永永, 等. 基于多传感器数据融合的 SA-DACNN 齿轮箱故障诊断方法[J]. 控制与决策, 2024, 39(11): 3699-3708.

## SA-DACNN gearbox fault diagnosis method based on multi-sensor data fusion

ZHANG Ya-zhou<sup>1,2</sup>, ZHAO Xiao-qiang<sup>1,2†</sup>, HUI Yong-yong<sup>1,2</sup>, CHEN Peng<sup>3</sup>

(1. College of Electrical Engineering and Information Engineering, Lanzhou University of Technology, Lanzhou

730050, China; 2. Key Laboratory of Advanced Control of Industrial Processes in Gansu Province, Lanzhou 730050,

China; 3. College of Electrical and Electronic Engineering, Lanzhou Petrochemical University of Technology,

Lanzhou 730050, China)

**Abstract:** To address the problem that single sensor data are easily affected by their own quality and environment, which makes it difficult to monitor the overall operating condition of gearboxes, a SA-DACNN (self attention-dynamic adaptive convolutional neural network) gearbox fault diagnosis method based on multi-sensor data fusion is proposed. Firstly, the method treats the collected sensor signals from different locations as multi-channel signals and uses the multi-channel signals as network inputs simultaneously. Then, a multi-channel feature fusion module is designed, which solves the feature-level multi-channel data fusion problem by adaptively weighting the information of different channels to ensure that the important information of different channels can be effectively fused. Finally, before the fully connected layer, a self-attentive module with residual connections is used to help the network automatically learn global information and enhance the feature learning ability of the original vibration signals. Experiments are conducted on two gearbox datasets, and the results show that the proposed method has a high fault diagnosis accuracy and can meet the task of multi-sensor data fusion fault diagnosis.

**Keywords:** fault diagnosis; multi-sensor data; data fusion; gearbox; convolutional neural network; self attention

## 0 引言

齿轮箱作为机械传动系统的核心部件, 其可靠性对于设备的安全运行至关重要. 由于重要部位的

齿轮发生故障, 可能会阻碍机械系统进行正常生产并导致经济损失. 因此, 如何对齿轮箱进行有效故障检测和诊断, 及时发现设备的故障, 防止出现计划外停

收稿日期: 2023-09-25; 录用日期: 2024-01-16.

基金项目: 国家自然科学基金项目(62263021); 甘肃省青年科技基金计划项目(22JR5RA808).

责任编辑: 赵春晖.

†通讯作者. E-mail: xqzhao@lut.edu.cn.

机并减少昂贵的维修费用具有重大的研究意义<sup>[1-2]</sup>.

随着传感器技术的发展,数据采集变得更加方便,因此,基于数据驱动的深度学习方法在机械故障诊断中得到快速发展<sup>[3-5]</sup>.然而,单一传感器获得的信息有限且容易受到外界因素的干扰,难以监控齿轮箱的整体状况.为了全面了解齿轮箱的状况,提升故障诊断精度,对齿轮箱布置多个传感器采集信息,并通过多源信息融合技术将多个传感器信息进行融合,最终获得互补信息已成为机械设备故障诊断发展的研究热点<sup>[6]</sup>.

多传感器信息融合包含3个策略级融合:数据级融合、特征级融合以及决策级融合<sup>[7]</sup>.数据级融合是指将多个传感器采集的原始数据在网络输入层之前直接进行融合.例如:Jing等<sup>[8]</sup>将多个传感器采集的原始数据直接融合,提出了一种基于深度卷积神经网络的行星齿轮箱故障诊断方法;Azamfar等<sup>[9]</sup>将多个电流传感器采集的原始信号进行融合,然后使用二维卷积神经网络进行齿轮箱故障诊断.数据级融合可以充分利用原始数据克服特征信息丢失,但是此类方法需要人为选取原始数据,且缺乏可解释性.决策级融合是指将每个传感器的特征信息在网络的输出层进行融合.例如:杨洁等<sup>[10]</sup>将多个传感器数据输入到一维卷积神经网络进行特征提取,然后在全连接层将每个传感器的特征信息进行融合,最终实现航空发动机轴承故障诊断;Gong等<sup>[11]</sup>提出了基于改进卷积神经网络和多传感器数据融合的快速异常诊断方法,该方法以多传感器数据为输入,在全连接层进行特征融合.决策级融合拥有较好的可解释性和实用性,但是此类方法进行特征融合时信息丢失严重,故障诊断效果不理想.特征级融合是指使用特征选择方法在特征提取过程中进行信息融合.例如:Xu等<sup>[12]</sup>提出了一种基于加权软投票规则的多注意力模块多尺度信息融合的机械维修智能故障诊断方法,该方法充分考虑了不同尺度的特征对网络决策层的贡献,解决了多尺度网络在复杂环境下故障诊断低效的问题;Zhang等<sup>[13]</sup>提出了一种计算资源较少的多传感器振动信号故障诊断方法,该方法在特征层进行多层特征融合,并使用多层池化分类器取代传统卷积网络的全连接层,有效地减少了网络参数量和过拟合风险.特征级融合可以将原始高维数据进行压缩降维,但是此类方法需要领域知识.

综上所述,基于多传感器信息融合的故障诊断方法取得了令人鼓舞的成果,但是仍然存在一些问题,例如:数据级融合信息损失小,但该融合方法研究有

限,不同类型的原始数据进行融合缺乏理论解释;决策级融合可解释性好,但是特征信息损失巨大,诊断效果不佳;特征级融合尽管依赖领域知识,但特征信息损失较小,易于实现,所以本文采用多传感器特征级融合策略.此外,考虑到深度学习具有较强大的特征提取能力,不需要手动提取特征.因此,本文提出一种基于多传感器特征级数据融合的SA-DACNN故障诊断方法.首先,设计一种高效的多通道特征融合模块,解决特征层面的多通道数据融合问题;然后,为了更好地学习特征信息和标签之间的映射关系,使用带残差连接的自注意力模块进行全局信息建模,帮助网络捕获不同通道特征信息对输出结果的贡献度.与其他方法相比,本文方法可以动态自适应地融合不同传感器的特征信息,对专家知识和人力的依赖性较小.

## 1 一维卷积神经网络(1DCNN)

CNN是一种前馈深度学习模型,被广泛应用于计算机视觉和模式识别任务中<sup>[14-15]</sup>.近年来,卷积神经网络也被成功应用于机械故障诊断领域<sup>[16-18]</sup>.在工业现场,传感器采集的信号通常为一维时域信号,因此本文选用一维卷积神经网络作为基本网络.一维卷积神经网络由卷积层、池化层、激活层和全连接层组成.卷积层能够对上一层输出进行点积操作,提取局部区域的特征<sup>[19]</sup>,其公式为

$$Z_{l' \times w'}^{j+1} = f(W_{l \times w}^j \otimes X_{s \times w}^j + b^j). \quad (1)$$

其中: $W_{l \times w}^j$ 表示第 $j$ 层卷积核的权重, $l$ 和 $w$ 分别表示卷积核的长度和宽度; $X_{s \times w}^j$ 表示上一层输入, $s$ 表示上一层输入的长度; $b^j$ 表示第 $j$ 层卷积核的偏差; $\otimes$ 表示点积操作; $Z_{l' \times w'}^{j+1}$ 表示卷积层输出.

池化层能够进一步压缩卷积层输出特征图的维度,降低参数量<sup>[20]</sup>.池化层不会改变特征图的宽度,其公式为

$$P_l^{j+1}(i) = \max\{a_w^j(t)\}, t \in [(i-1)w+1, iw]. \quad (2)$$

其中: $w$ 表示池化区域的宽度; $a_w^j(t)$ 表示第 $t$ 层的第 $P_l^{j+1}(i)$ 个神经元,表示池化层输出值.

全连接层能够将卷积层和池化层输出的特征进行非线性组合,得到最终的特征向量.在分类任务中,使用Softmax做分类器,其公式为

$$Y_i = \begin{bmatrix} P(y_i = 1|x_i) \\ P(y_i = 2|x_i) \\ \vdots \\ P(y_i = n|x_i) \end{bmatrix}^T = \frac{1}{\sum_{l=1}^n e^{x_i^T w_l}} \begin{bmatrix} e^{x_i^T w_1} \\ e^{x_i^T w_2} \\ \vdots \\ e^{x_i^T w_n} \end{bmatrix}^T. \quad (3)$$

其中:  $Y_i$  表示第  $i$  个样本 Softmax 归一化输出结果,  $Y_i$  输出结果在  $[0, 1]$  之间;  $1 / \sum_{l=1}^n e^{x_i^T w_l}$  表示对输出概率  $[e^{x_i^T w_1}, e^{x_i^T w_2}, \dots, e^{x_i^T w_n}]$  的归一化结果.

## 2 基于SA-DACNN的多传感器数据融合故障诊断方法

### 2.1 多通道特征融合模块

齿轮箱通常被安装多个传感器监测其运行状态, 单一传感器只能采集固定位置的机械故障信息, 无法捕获齿轮箱的整体运行情况. 为了充分利用不同方向、不同位置的传感器采集的数据, 本文设计了一个多通道特征融合模块, 如图1所示. 该多通道特征融合模块通过自适应地加权不同通道的信息, 确保不同通道的重要信息能够有效地融合.

多通道特征融合模块可分为3个步骤.

step 1: 将不同通道的特征信息  $x_1, x_2, \dots, x_k, x_{k+1}$  进行特征融合(元素相加), 获得新的特征信息图, 其公式为

$$U = x_1 + x_2 + \dots + x_k + x_{k+1}. \quad (4)$$

其中:  $x_1, x_2, \dots, x_k, x_{k+1}$  表示不同通道的输入特征,  $1, 2, \dots, k$  和  $k+1$  分别表示第1通道、第2通道、第  $k$  通道和第  $k+1$  通道,  $U$  表示特征融合后的值.

step 2: 首先通过全局平均池化将特征信息展平为一维特征, 实现特征降维, 即  $U_{gap}$ , 然后通过 Softmax 函数加权不同通道的特征信息, 其公式为

$$\hat{x}_1 = e^{U_{gap}^1} / \sum_{j=1}^{k+1} e^{U_{gap}^j}, \quad (5)$$

$$\hat{x}_2 = e^{U_{gap}^2} / \sum_{j=1}^{k+1} e^{U_{gap}^j}, \quad (6)$$

$$\hat{x}_k = e^{U_{gap}^k} / \sum_{j=1}^{k+1} e^{U_{gap}^j}, \quad (7)$$

$$\hat{x}_{k+1} = e^{U_{gap}^{k+1}} / \sum_{j=1}^{k+1} e^{U_{gap}^j}, \quad (8)$$

$$\hat{x}_1 + \hat{x}_2 + \dots + \hat{x}_k + \hat{x}_{k+1} = 1. \quad (9)$$

其中:  $\hat{x}_1, \hat{x}_2, \dots, \hat{x}_k, \hat{x}_{k+1}$  表示不同通道特征经过 Softmax 函数归一化后的输出值,  $e^{U_{gap}^1}, e^{U_{gap}^2}, \dots, e^{U_{gap}^k}$  和  $e^{U_{gap}^{k+1}}$  分别表示第  $1, 2, \dots, k$  和  $k+1$  通道的转变为  $0 \sim 1$  之间的概率值,  $\sum_{j=1}^{k+1} e^{U_{gap}^j}$  表示对所有通道的概率值求和.

step 3: 将 Softmax 函数输出值和输入特征图相乘, 生成新的加权特征图, 并将新的特征图进行融合, 其公式为

$$u_i = x_i \hat{x}_i, \quad (10)$$

$$\vec{U} = \sum_{i=1}^{k+1} u_i. \quad (11)$$

其中:  $u_i$  表示第  $i$  通道生成的加权特征图,  $\vec{U}$  表示多通道特征融合模块的输出.




图1 多通道特征融合模块

### 2.2 自注意力模块

目前, 注意力机制被广泛使用于自然语言处理领域, 注意力机制可以帮助网络更加关注对输出有贡献的特征信息<sup>[21-22]</sup>. 为了使网络更好地学习特征信息与标签之间的映射关系, 本文在全连接输出层前使用带残差连接的自注意力模块(residual self attention module, RSAM), RSAM能够自动学习特征之间的相关性, 并根据相关性加权处理输入特征, 使其更加关注有用信息, 同时抑制无关信息, 从而提高网络的故

障诊断准确率, RSAM如图2所示.

在图2中, RSAM处理过程可以分为3个步骤.

step 1: 输入特征图  $X$  经过线性变化分别得到查询矩阵  $Q_i$ 、键矩阵  $K_i$  和值矩阵  $V_i$ , 其公式为

$$Q_i = XW_i^Q, \quad (12)$$

$$K_i = XW_i^K, \quad (13)$$

$$V_i = XW_i^V. \quad (14)$$

其中:  $W_i^Q, W_i^K, W_i^V$  为线性变化的参数矩阵, 参数矩

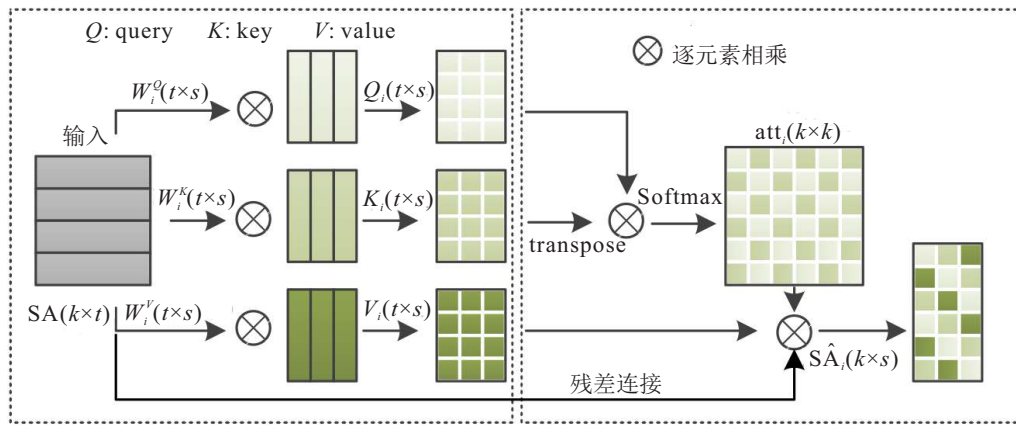


图2 残差自注意力模块

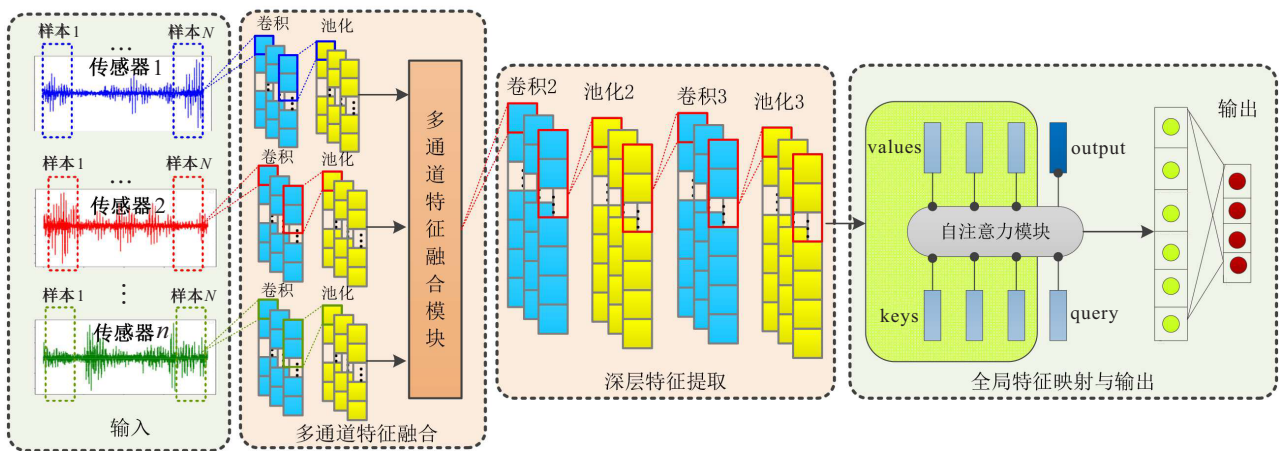


图3 SA-DACNN 诊断框架

阵通过训练网络不断学习。

step 2: 键矩阵  $K_i$  进行转置得到  $K_i^T$ , 将  $K_i^T$  和查询矩阵  $Q_i$  进行点乘运算得到两个向量之间的相关性, 通过 Softmax 函数计算残差自注意力模块的权重矩阵, 其数学描述为

$$att_i = \text{Softmax}\left(\frac{Q_i K_i^T}{\sqrt{d}}\right), \quad (15)$$

其中  $d$  表示参数矩阵的维数。

step 3: 值矩阵  $V_i$  和  $att_i$  进行矩阵乘法运算, 并与输入特征进行残差连接得到自注意力模块的输出, 其数学描述为

$$\widehat{SA}_i = V_i att_i, \quad (16)$$

$$RSA_i = \widehat{SA}_i + SA. \quad (17)$$

其中:  $V_i$  表示值矩阵,  $att_i$  表示残差自注意模块的权重矩阵,  $\widehat{SA}_i$  表示自注意力输出,  $SA$  表示残差自注意模块的输入。

### 2.3 多传感器数据融合诊断流程

单一传感器只能获取固定位置的故障信息且容易受到传感器自身性能的影响, 难以体现整个齿轮箱的运行状态. 多源传感器数据融合可以获得更

多的故障信息, 为设备运行维护人员提高更加可靠的维修决策. 因此, 本文提出一种基于多传感器数据融合的 SA-DACNN 故障诊断方法. 该方法无需对原始数据做任何手工处理, 只需将传感器采集的振动信号输入 SA-DACNN 网络, 诊断结果自动输出. SA-DACNN 诊断网络主要由输入层、特征提取层、多通道特征融合模块、带残差连接的自注意力模块和输出层组成, 网络结构如图3所示. 该网络将传统 1DCNN 单输入方式改进为多传感器振动信号的多通道输入, 然后经过卷积、激活函数和最大池化对不同通道的传感器数据进行特征提取, 接着通过多通道特征融合模块对不同通道的特征信息进行加权融合, 最后使用卷积、池化操作提取深层特征信息. 此外, 在输出层之前, 使用了带残差连接的自注意力模块, 该模块能够关注网络中每一层的全局信息, 增强了对不同传感器振动信号的深层特征学习能力, 有效地提升网络故障识别准确率.

图4为 SA-DACNN 的流程图, 其诊断步骤为:

step 1: 采集齿轮箱不同位置的传感器信号;

step 2: 对传感器信号进行数据处理, 划分数据为

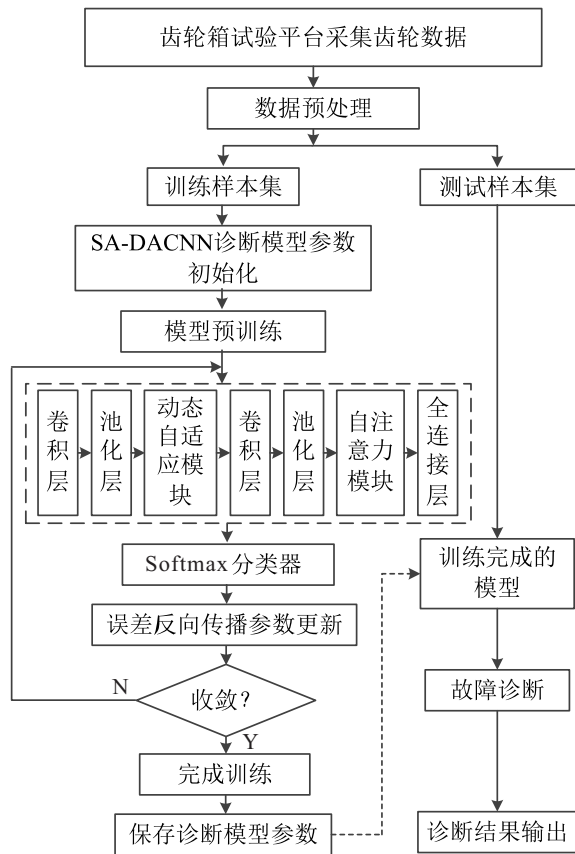


图 4 SA-DACNN 诊断逻辑流程

训练样本集、验证样本集和测试样本集,其中训练样本集和验证样本集用于训练模型,测试样本集用于验证模型;

step 3: 模型参数初始化,并将训练样本集和验证样本集输入模型,通过误差反向传播算法优化模型参数;

step 4: 判断模型是否收敛,若收敛则完成训练并保存模型参数,若不收敛则返回执行 step 3;

step 5: 测试样本集输入已经训练完成的模型,然后通过模型进行特征提取,最终输出故障诊断结果。

### 3 实验仿真与结果分析

在本章节中,使用两个齿轮箱数据评估所提出方法的故障诊断效果。实验的电脑配置为 AMD 锐龙 5-4600H 处理器,实验框架为 keras-python。

#### 3.1 案例 1

##### 3.1.1 数据集描述

实验数据由东南大学动力传动系统动态模拟实验平台提供<sup>[23]</sup>。该平台模拟了负载设置在 20 Hz-0 V 和 30 Hz-2 V 工况下,5 种齿轮类型的实验数据。5 种齿轮类型分别为齿轮断齿、齿轮缺口、齿面磨损、齿根裂纹和正常状态。此外,该平台采集了电机振动和扭矩、行星齿轮箱 3 个方向(X、Y、Z)和平行齿轮箱 3 个方向(X、Y、Z)共 8 个通道的实验数据。在本

案例中,选取 4 个通道的实验数据,每种齿轮故障类型取 600 个样本,并按照 3:1 比例划分训练集和测试集,具体数据选取和划分如表 1 所示。

表 1 东南大学数据集划分

工况	类别	训练集	测试集	标签
20 Hz-0 V	齿轮断齿	450	150	0
	齿轮缺口	450	150	1
	齿面磨损	450	150	2
	齿根裂纹	450	150	3
	正常状态	450	150	4
30 Hz-2 V	齿轮断齿	450	150	5
	齿轮缺口	450	150	6
	齿面磨损	450	150	7
	齿根裂纹	450	150	8
	正常状态	450	150	9

##### 3.1.2 SA-DACNN 网络参数设计

SA-DACNN 网络在训练中采用 Adam 自适应优化算法,在全连接层使用 Dropout 防止网络出现过拟合问题,批次大小设置为 96,循环迭代次数为 100,模型的其他超参数设计如表 2 所示。表 2 中 [batch, 2048, 1]×4 表示 4 个通道输入层的结构参数,每个通道具有相同的结构参数,2048 表示每个样本的采样点长度,1 表示卷积操作的通道数。

表 2 网络结构参数

结构名称	结构参数	输出形状	参数量
输入层	[batch, 2048, 1]×4	[batch, 2048, 1]×4	0
卷积层 1	[32, 1, 16]×4	[batch, 128, 16]×4	528×4
激活层 1	Relu 激活函数	[batch, 128, 16]×4	0
池化层 1	[2, 1, 1]×4	[batch, 64, 16]×4	0
多通道特征融合模块	—	[batch, 64, 16]	0
卷积层 2	[3, 1, 32]	[batch, 64, 32]	1568
激活层 2	Relu 激活函数	[batch, 64, 32]	0
池化层 2	[2, 1, 1]	[batch, 32, 32]	0
卷积层 3	[3, 1, 64]	[batch, 32, 64]	6208
激活层 3	Relu 激活函数	[batch, 32, 64]	0
池化层 3	[2, 1, 1]	[batch, 16, 64]	0
自注意力层	[12]	[batch, 16, 12]	2304
全连接层	—	[batch, 100]	19300
Softmax 层	—	[batch, 10]	1010

##### 3.1.3 可视化分析

为了更好地理解 SA-DACNN 特征提取过程,本文把 4 个通道的实验数据输入到 SA-DACNN 中,通过 t-SNE 技术将各层提取的特征降维可视化,结果如图 5 所示。由图 5 可知,10 种原始数据刚开始输入网络

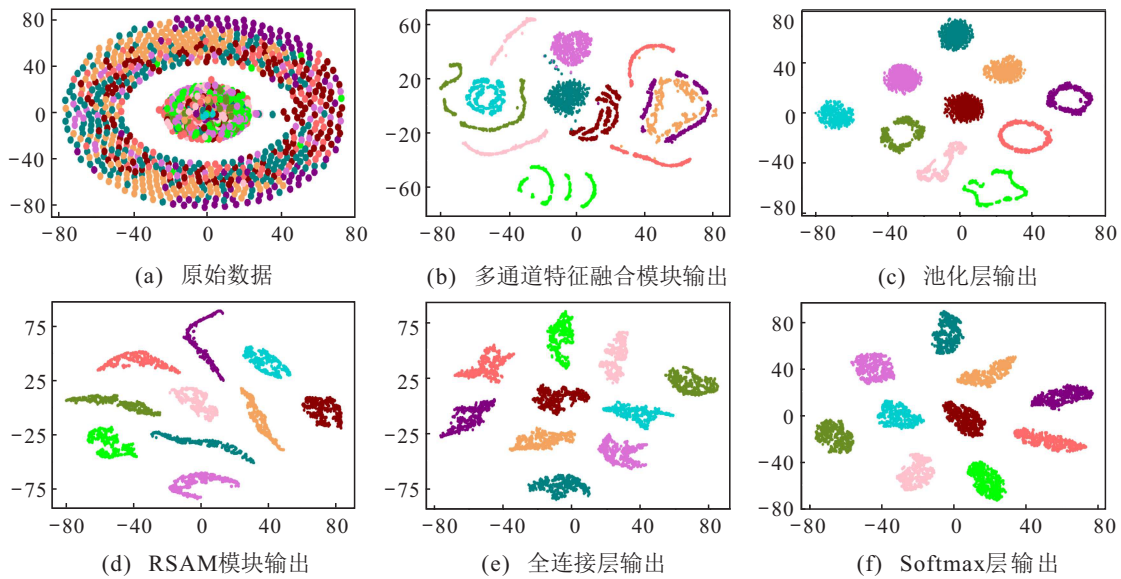


图5 东南大学数据集  $t$ -SNE 各层特征降维可视化

时,分布散乱无序,难以判别;经过多通道特征融合模块后,多数样本可以区分,然而仍存在一些故障样本误分的情况;最后经过池化层、自注意力模块、全连接层和 Softmax 层处理后,10种故障样本被完全分离,不同类型的故障样本不重叠.

3.1.4 多通道数据融合分析

为了分析 SA-DACNN 中多通道特征融合模块对多通道特征信息融合的效果,本文进行单通道、2通道和3通道输入实验,具体实验设计和实验结果如表3所示.由表3可知,当输入为单通道时,齿轮箱 X、Y 和 Z 轴的振动信号的诊断精确率高于电机端振动信

号的诊断精确率,这是因为电机端振动信号的幅值变化较大,导致故障信息难以提取;当输入为2通道时,齿轮箱端的振动信号和电机端振动信号无论以何种组合,其诊断精确率均高于单通道输入的诊断精确率,当输入为齿轮箱 X 轴和齿轮箱 Y 轴时,故障诊断精确率为 95.60%;当输入为3通道时,齿轮箱 X、Y 和 Z 轴的振动信号的诊断精确率已高达 99.20%.通过以上分析可知,随着输入通道数增加,故障诊断精确率也逐渐增加,这表明本文设计的多通道特征融合模块能够有效地加权不同通道的权重,突出重要通道的权重,抑制其他干扰信息.

表3 多通道数据融合诊断多指标结果

通道选择	信号类型	精确率 / %	召回率 / %	$F_1$ 均值 / %
单通道	电机端信号	83.14	84.34	81.63
	齿轮箱 X 轴	91.73	91.36	90.82
	齿轮箱 Y 轴	91.40	91.29	90.77
	齿轮箱 Z 轴	88.80	90.27	88.71
2通道	电机端信号、齿轮箱 X 轴	92.80	93.68	92.55
	电机端信号、齿轮箱 Y 轴	92.77	93.51	92.37
	电机端信号、齿轮箱 Z 轴	91.59	91.89	91.58
	齿轮箱 X 轴、齿轮箱 Y 轴	95.60	95.90	95.60
	齿轮箱 X 轴、齿轮箱 Z 轴	94.81	94.59	94.57
	齿轮箱 Y 轴、齿轮箱 Z 轴	94.00	94.59	94.06
3通道	电机端信号、齿轮箱 X、Y 轴	98.33	98.27	98.32
	电机端信号、齿轮箱 X、Z 轴	98.31	98.19	98.20
	齿轮箱 X 轴、齿轮箱 Y、Z 轴	99.20	99.17	98.99

3.1.5 不同方法性能比较

为了进一步验证 SA-DACNN 的故障诊断能力,本文选取 2D-CNN<sup>[9]</sup>、HMS-MACNN<sup>[12]</sup>、MLPC-

CNN<sup>[13]</sup>、P-2DCNN<sup>[24]</sup>、BP、LSTM、SA-CNN 和 DACNN 与本文所提出方法进行比较,对比方法具体描述如下:

1) MLPC-CNN 为多层特征融合卷积神经网络, 该网络使用单传感器单通道卷积 (SSTSC) 处理所有的传感器数据, 使用两个卷积层, 在旁路分支使用平均池化, 学习率优化方法为 SGDM;

2) 2D-CNN 网络由 2 个卷积层、2 个最大池化层和 2 个 FC 全连接层组成;

3) HMS-MACNN 为混合多尺度卷积神经网络, 该网络采用多尺度技术和自适应加权的多注意模块进行特征提取和故障识别, 网络由 2 个混合多尺度模块、3 个卷积层和 2 个注意力模块组成;

4) P-2DCNN 网络将不同位置传感器时域振动信号构造成二维矩阵, 网络由 2 个卷积层、2 个池化层组成;

5) BP 和 LSTM 选取是为了与 CNN 网络做对比;

6) SA-CNN 网络的结构参数与本文所提出方法一样, 不同之处是网络中没有多通道特征融合模块;

7) DACNN 网络无自注意力模块, 其结构参数配置与本文方法一样。

为了消除随机因素引起的干扰, 以上实验重复 10 次, 并采用 10 次实验的诊断准确率的平均值和标准差来评价各种方法的性能, 实验结果如表 4 所示。由表 4 可知, 本文所提出方法的训练准确率和测试准确率都高于对比方法, 训练准确率和测试准确率为 100%, 并且每批次的训练时间为 1.7 s。这表明: 本文方法在故障诊断准确率和时效性方面具有一定的优势。相比于 BP 和 LSTM 的方法, 本文方法的测试准确率分别提高了 25.07% 和 15.67%, 表明卷积模型在特征提取和分类方面拥有其他网络无法比拟的优势。相比于 MLPC-CNN 和 HMS-MACNN 的方法, 本文方法的测试集故障诊断精度分别提高了 2.53% 和 1.83%, 表明所设计的多通道特征融合模块能够对不同通道的传感器数据加权, 提升故障识别准确率。相比于 2D-CNN 和 P-2DCNN 的方法, 本文方法的故障诊断精度分别提高了 4.04% 和 3.95%, 表明 1D 卷积网络更加适合振动信号的特征提取。相比于 SA-CNN 和 DACNN, 本文方法的故障诊断精度分别提高

了 1.90% 和 0.59%, 表明自注意力模块和多通道特征融合模块能够增强网络的故障辨识能力和泛化能力。

表 4 不同方法的故障诊断结果

不同方法	训练准确率 / %		测试准确率 / %		训练速度 / (s/batch)
	平均值	标准差	平均值	标准差	
BP	95.49	1.62	74.93	4.14	10.95
LSTM	96.90	0.96	84.33	3.77	45.32
MLPC-CNN	99.27	0.37	97.47	6.01	4.95
2D-CNN	99.81	0.10	95.96	3.91	6.51
HMS-MACNN	99.52	0.28	98.17	3.93	19.89
P-2DCNN	97.39	0.86	96.05	3.46	3.90
SA-CNN	99.95	0.12	98.10	4.23	1.61
DACNN	99.96	0.03	99.41	1.34	1.53
SA-DACNN	100.0	0.00	100.0	0.00	1.70

### 3.2 案例 2

#### 3.2.1 数据集描述

实验数据来源于滚轴齿轮故障模拟试验平台。该平台由三相交流异步电机、加载装置、测试轴承箱、传动机构、齿轮箱和变频控制器组成。本案例被测对象为锥齿轮, 锥齿轮的故障状态分别为全齿断裂、小端断半齿、大端断半齿、均匀磨损和正常状态 5 种不同的锥齿轮状态。实验数据由安装在 9 点方向和 12 点方向上的剪切加速度传感器采集, 信号采样频率为 25.6 kHz。本文选取电机运行频率为 20 Hz、锥齿轮加载为 1 HP 的实验数据, 每种锥齿故障样本数为 600, 按照 3 : 1 比例划分训练集和测试集, 数据集具体划分如表 5 所示。

表 5 滚轴齿轮数据集划分

类别	训练集	测试集	标签
齿轮大端断半齿	450	150	0
齿轮均匀磨损	450	150	1
齿轮全齿断裂	450	150	2
齿轮小端断半齿	450	150	3
齿轮正常	450	150	4

#### 3.2.2 可视化分析

为了验证所提出方法的特征提取能力, 选用 *t*-SNE 技术将各个模块的特征进行可视化, 如图 6 所示。




图 6 滚轴齿轮数据集 *t*-SNE 各层特征降维可视化

由图6可以看出:原始数据随机分布在二维可视化图中,各个故障样本不能区分;多通道特征融合模块能够让特征彼此分离,相同的特征呈现聚集状态;Softmax层将相同特征完全聚类,不同特征完全分离.通过可视化分析,表明本文所提出方法具有较好的故障识别能力和良好的聚类性能.


3.2.3 多通道数据融合分析

同案例1一样,对案例2进行单通道和2通道输入实验,实验设计和实验结果如表6所示.由表6可知,当输入为单通道时,齿轮箱X轴和Y轴的诊断精确率分别为97.86%和95.46%;当输入为2通道时,所


提出方法的诊断精确率已高达99.73%,这表明所设计的多通道特征融合模块能够对不同通道的传感器数据加权,可以提升故障识别准确率.此外,为了更直观地显示诊断效果,采用混淆矩阵对锥齿轮故障识别能力进一步分析,结果如图7所示.由图7可知,单通道齿轮箱X轴输入时,即SA-DACNN1,标签2和标签3对应故障类型为齿轮全齿断裂和齿轮小端断半齿,存在5%的样本被误诊为其他类型故障.相比之下,本文所提出方法除了将1%的齿轮小端断半齿被误诊为正常状态外,其他样本的故障诊断准确率为100%.

表6 多通道数据融合诊断多指标结果

通道选择	信号类型	精确率/%	召回率/%	F <sub>1</sub> 均值/%
单通道	齿轮箱X轴	97.86	97.97	97.87
	齿轮箱Y轴	95.46	95.52	95.37
2通道	齿轮箱X轴、齿轮箱Y轴	99.73	99.72	99.73



(a) SA-DACNN<sup>1</sup>



(b) SA-DACNN

图7 多通道数据融合混淆矩阵

结果如表7所示.由表7可以看出:所有方法的平均训练准确率均在95%以上,其中SA-DACNN的训练准确率为99.94%,是所有方法中最好的;SA-DACNN的平均测试准确率为99.64%,比HMS-MACNN方法高2.95%,比2D-CNN方法高1.78%.此外,基于CNN模型的方法测试准确率明显高于BP和LSTM,这是因为BP和LSTM网络结构简单,未采用先进的模块导致特征提取能力不足;与SA-CNN和DACNN方法相比,去掉多通道特征融合模块后,测试准确率下降了1.01%,去掉自注意力模块后,测试准确率下降了0.87%.这表明本文所设计的多通道特征融合模块能够有效地加权不同通道的特征,提高故障诊断精度;自注意力模块的引入可以帮助网络提取到深层网络的重要特征.由以上分析可知,本文所提出方法的故障诊断准确率明显高于对比方法,并且收敛速度更快.

表7 滚轴齿轮数据集的故障诊断结果

不同方法	训练准确率/%		测试准确率/%		训练速度/(s/batch)
	平均值	标准差	平均值	标准差	
BP	96.81	0.63	74.53	1.76	5.07
LSTM	97.42	0.47	84.42	2.93	23.2
MLPC-CNN	99.90	0.10	98.00	2.85	1.43
2D-CNN	99.76	0.39	97.86	2.56	2.47
HMS-MACNN	99.32	0.99	96.69	4.43	3.43
P-2DCNN	99.60	0.38	98.80	0.62	1.60
SA-CNN	99.77	0.36	98.63	2.57	0.63
DACNN	99.64	0.45	98.77	2.31	0.55
SA-DACNN	99.94	0.06	99.64	0.39	0.71

3.2.4 不同方法性能比较

与案例1相同,本文仍然选用BP、LSTM、MLPC-CNN、2D-CNN、HMS-MACNN、P-2DCNN、SA-CNN和DACNN与所提出方法SA-DACNN作对比,对比

## 4 结 论

为了解决单一传感器数据下齿轮箱故障诊断效果差的问题,本文提出了一种基于SA-DACNN的多传感器数据融合故障诊断方法,并得到以下结论:

1) 本文设计的多通道特征融合模块可以融合不同通道的传感器数据,并自适应地增强有用特征信息,抑制干扰信息;带残差连接的自注意力模块可以帮助网络更好地学习特征信息和标签之间的映射关系,提升齿轮箱的故障诊断准确率。

2) 本文使用两个齿轮箱数据验证方法的有效性,分析了单个传感器与多传感器数据对诊断效果的影响,结果表明多传感器数据融合可以获得更加全面的故障特征,有效提高了故障识别精度。

3) 虽然本文方法可以解决多传感器数据融合问题,但是齿轮箱通常运行在变工况环境下,不同工况下故障诊断结果有所差异,因此未来将针对变工况下齿轮箱多传感器数据融合做进一步研究。

### 参考文献(References)

- [1] Zhang L J, Wang B, Liang P F, et al. Semi-supervised fault diagnosis of gearbox based on feature pre-extraction mechanism and improved generative adversarial networks under limited labeled samples and noise environment[J]. *Advanced Engineering Informatics*, 2023, 58: 102211.
- [2] Zhu Y Y, Pei Y, Wang A Q, et al. A partial domain adaptation scheme based on weighted adversarial nets with improved CBAM for fault diagnosis of wind turbine gearbox[J]. *Engineering Applications of Artificial Intelligence*, 2023, 125: 106674.
- [3] 王进花, 岳亮辉, 曹洁, 等. 基于随机变分推理贝叶斯神经网络的发电机轴承故障诊断[J]. *控制与决策*, 2023, 38(4): 1015-1021.  
(Wang J H, Yue L H, Cao J, et al. Fault diagnosis of generator bearing based on stochastic variational inference Bayesian neural network[J]. *Control and Decision*, 2023, 38(4): 1015-1021.)
- [4] 梁浩鹏, 曹洁, 赵小强. 基于GADF和PAM-Resnet的旋转机械小样本故障诊断方法[J]. *控制与决策*, 2023, 38(12): 3465-3472.  
(Liang H P, Cao J, Zhao X Q. Small sample fault diagnosis method for rotating machinery based on GADF and PAM-Resnet[J]. *Control and Decision*, 2023, 38(12): 3465-3472.)
- [5] Zhao X Q, Zhang Y Z. An intelligent diagnosis method of rolling bearing based on multi-scale residual shrinkage convolutional neural network[J]. *Measurement Science and Technology*, 2022, 33(8): 085103.
- [6] Shao H D, Lin J, Zhang L W, et al. A novel approach of multisensory fusion to collaborative fault diagnosis in maintenance[J]. *Information Fusion*, 2021, 74: 65-76.
- [7] Liu K B, Gebraeel N Z, Shi J J. A data-level fusion model for developing composite health indices for degradation modeling and prognostic analysis[J]. *IEEE Transactions on Automation Science and Engineering*, 2013, 10(3): 652-664.
- [8] Jing L Y, Wang T Y, Zhao M, et al. An adaptive multi-sensor data fusion method based on deep convolutional neural networks for fault diagnosis of planetary gearbox[J]. *Sensors*, 2017, 17(2): 414.
- [9] Azamfar M, Singh J, Bravo-Imaz I, et al. Multisensor data fusion for gearbox fault diagnosis using 2-D convolutional neural network and motor current signature analysis[J]. *Mechanical Systems and Signal Processing*, 2020, 144: 106861.
- [10] 杨洁, 万安平, 王景霖, 等. 基于多传感器融合卷积神经网络的航空发动机轴承故障诊断[J]. *中国电机工程学报*, 2022, 42(13): 4933-4942.  
(Yang J, Wan A P, Wang J L, et al. Aeroengine bearing fault diagnosis based on convolutional neural network for multi-sensor information fusion[J]. *Proceedings of the CSEE*, 2022, 42(13): 4933-4942.)
- [11] Gong W F, Wang Y Z, Zhang M L, et al. A fast anomaly diagnosis approach based on modified CNN and multisensor data fusion[J]. *IEEE Transactions on Industrial Electronics*, 2022, 69(12): 13636-13646.
- [12] Xu Z F, Bashir M, Zhang W F, et al. An intelligent fault diagnosis for machine maintenance using weighted soft-voting rule based multi-attention module with multi-scale information fusion[J]. *Information Fusion*, 2022, 86(C): 17-29.
- [13] Zhang Y L, He L, Cheng G. MLPC-CNN: A multi-sensor vibration signal fault diagnosis method under less computing resources[J]. *Measurement*, 2022, 188: 110407.
- [14] Jiao J Y, Zhao M, Lin J, et al. A comprehensive review on convolutional neural network in machine fault diagnosis[J/OL]. 2020, arXiv: 2002.07605.
- [15] 吴耀春, 赵荣珍, 靳伍银, 等. 面向数据不平衡的卷积神经网络故障辨识方法[J]. *振动测试与诊断*, 2022, 42(2): 299-307.  
(Wu Y C, Zhao R Z, Jin W Y, et al. Intelligent fault identification method based on convolutional neural network for imbalanced data[J]. *Journal of Vibration, Measurement & Diagnosis*, 2022, 42(2): 299-307.)
- [16] 姚齐水, 别帅帅, 余江鸿, 等. 一种结合改进Inception V2模块和CBAM的轴承故障诊断方法[J]. *振动工程学报*, 2022, 35(4): 949-957.

- (Yao Q S, Bie S S, Yu J H, et al. A bearing fault diagnosis method combining improved inception V2 module and CBAM[J]. Journal of Vibration Engineering, 2022, 35(4): 949-957.)
- [17] 宫文峰, 陈辉, 张泽辉, 等. 基于改进卷积神经网络的滚动轴承智能故障诊断研究[J]. 振动工程学报, 2020, 33(2): 400-413.  
(Gong W F, Chen H, Zhang Z H, et al. Intelligent fault diagnosis for rolling bearing based on improved convolutional neural network[J]. Journal of Vibration Engineering, 2020, 33(2): 400-413.)
- [18] 姚家琪, 荆华, 赵春晖. 一种面向噪声环境中旋转机械故障诊断的多模态耦合输入神经网络[J]. 控制与决策, 2023, 38(7): 1918-1926.  
(Yao J Q, Jing H, Zhao C H. A multimode coupled input neural network for rotating machinery fault diagnosis in noisy environment[J]. Control and Decision, 2023, 38(7): 1918-1926.)
- [19] Wang Y B, Huang J K, Wang Y, et al. A CNN-based adaptive surface monitoring system for fused deposition modeling[J]. ASME Transactions on Mechatronics, 2020, 25(5): 2287-2296.
- [20] Zhang W, Li C H, Peng G L, et al. A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load[J]. Mechanical Systems and Signal Processing, 2018, 100: 439-453.
- [21] Xu D Y, Qiu H B, Gao L, et al. A novel dual-stream self-attention neural network for remaining useful life estimation of mechanical systems[J]. Reliability Engineering & System Safety, 2022, 222: 108444.
- [22] Liu S W, Jiang H K, Wu Z H, et al. Data synthesis using deep feature enhanced generative adversarial networks for rolling bearing imbalanced fault diagnosis[J]. Mechanical Systems and Signal Processing, 2022, 163: 108139.
- [23] Shao S Y, McAleer S, Yan R Q, et al. Highly accurate machine fault diagnosis using deep transfer learning[J]. IEEE Transactions on Industrial Informatics, 2019, 15(4): 2446-2455.
- [24] Wang J X, Wang D Z, Wang S H, et al. Fault diagnosis of bearings based on multi-sensor information fusion and 2D convolutional neural network[J]. IEEE Access, 2021, 9: 23717-23725.

#### 作者简介

张亚洲(1996—), 男, 博士生, 从事旋转机械故障诊断与寿命预测等研究, E-mail: 1911599612@qq.com;

赵小强(1969—), 男, 教授, 博士生导师, 从事故障诊断、图像处理、数据挖掘等研究, E-mail: xqzhao@lut.edu.cn;

惠永永(1992—), 男, 副教授, 从事间歇过程故障检测与诊断等研究, E-mail: 1048393569@qq.com;

陈鹏(1992—), 男, 副教授, 从事旋转机械故障诊断等研究, E-mail: 1341987756@qq.com.