

DOI: 10.19650/j.cnki.cjsi.J2311253

# 基于数据融合和改进 MoCo 的工业机器人 抖动原因识别<sup>\*</sup>

陈仁祥<sup>1</sup>, 谢文举<sup>1</sup>, 徐向阳<sup>1</sup>, 陈才<sup>2</sup>, 张旭<sup>1</sup>

(1. 重庆交通大学交通工程应用机器人重庆市工程实验室 重庆 400074; 2. 重庆华数机器人有限公司 重庆 400714)

**摘要:**实际工程中工业机器人受关节控制参数不佳易引起末端抖动,抖动原因识别有助于定位关节异常及优化控制。而工业机器人抖动原因识别存在周期信号冗余度高、抖动方向多及抖动状态样本标签缺失的问题,故提出基于数据融合和改进动量对比学习(MoCo)的工业机器人抖动原因识别方法。首先,对工业机器人末端各传感器数据依次进行数据降维、数据扩充、水平拼接融合及降维,构建充足且全面反映抖动方向及状态信息的融合样本。其中,数据融合前降维可降低周期样本冗余度及提升样本融合效率,数据融合后降维可避免融合样本过长导致模型训练复杂度增加。其次,在 MoCo 前标记少量融合样本由正编码器分类通道输出监督信息,引导特征聚类。然后,改进对比学习策略,将正编码器提取的无标签融合数据特征与动量编码器保存的负样本特征的聚类中心进行对比,去除特征相似度最高的聚类中心以降低对比类别错误的假负样本干扰。并通过对称调换两个编码器的输入进行两次对比损失计算,完成编码器训练。最后,在编码器分类通道后添加 Softmax 分类器完成工业机器人抖动原因识别。实验结果表明,所提方法在不同工况的工业机器人抖动原因识别准确率均在 90% 以上,证明了该方法的有效性。

**关键词:**工业机器人;抖动原因识别;数据融合;对比学习

中图分类号: TH165<sup>+</sup>.3 TP18 文献标识码: A 国家标准学科分类代码: 510. 40

## Recognition of jitter causes for industrial robots based on data fusion and the improved MoCo

Chen Renxiang<sup>1</sup>, Xie Wenju<sup>1</sup>, Xu Xiangyang<sup>1</sup>, Chen Cai<sup>2</sup>, Zhang Xu<sup>1</sup>

(1. Chongqing Engineering Laboratory for Transportation Engineering Application Robot, Chongqing Jiaotong University,  
Chongqing 400074, China; 2. CQHS Roboter Corporation, Chongqing 400714, China)

**Abstract:** In actual engineering, poor joint control parameters can easily cause end-jitter in industrial robots. Recognizing the cause of the jitter can help locate joint anomalies and optimize control. However, there are problems with identifying the cause of jitter in industrial robots, such as high redundancy of cyclic signals, multiple jitter directions, and missing sample labels. Therefore, a method for recognizing the cause of jitter in industrial robots based on data fusion and the improved momentum contrast (MoCo) is proposed. Firstly, the data of each sensor at the end of the industrial robot are sequentially subjected to data dimensionality reduction, data expansion, horizontal splicing fusion, and dimensionality reduction to construct fusion samples that reflect sufficient and comprehensive jitter direction and state information. Data dimensionality reduction before fusion can reduce the redundancy of periodic samples and improve the efficiency of sample fusion, while dimensionality reduction after fusion can avoid the complexity of model training caused by excessively long fusion samples. Secondly, a small number of labeled fusion samples are supervised by the positive encoder classification channel output information before MoCo to guide feature clustering. Then, an improved contrastive learning strategy is implemented. The unlabeled fused data features extracted by the positive encoder are compared with the cluster centers of the negative sample features saved by the momentum encoder, and the cluster centers with the highest feature similarity are removed to reduce the false negative sample interference of the comparison category error. And the encoder training is completed by symmetrically swapping the inputs of the two

收稿日期:2023-04-03 Received Date: 2023-04-03

\*基金项目:国家自然科学基金(51975079)、重庆市教委科学技术研究项目(KJZD-M202200701)、重庆市研究生联合培养基地项目(JDLHPYJD2021007)、重庆市专业学位研究生教学案例库(JDALK2022007)、重庆市研究生科研创新项目(2021S0037)资助

encoders for two comparison loss calculations. Finally, the cause of jitter in industrial robots is identified by adding a Softmax classifier to the encoder classification channel. The experimental results show that the recognition accuracy of the proposed method the causes of industrial robot jitter in different working conditions is larger than 90%, which shows the effectiveness of the method.

**Keywords:** industrial robot; recognition of jitter causes; data fusion; contrastive learning

## 0 引言

工业机器人具有效率高、精度高和重复性优秀的特点,是当前工业生产中不可或缺的智能制造设备<sup>[1]</sup>。然而,工业机器人受控制参数不佳、结构刚度低、轨迹不合理和末端负载变化等因素影响,存在抖动现象,将严重影响生产效率及产品质量<sup>[2]</sup>。其中,控制参数与工业机器人运动精度及稳定性直接关联,且调节控制参数能降低其余抖动因素的影响<sup>[3]</sup>。因此,进行工业机器人抖动原因识别,定位控制参数不佳的关节十分重要。

目前工业机器人抖动研究聚焦于抖动识别、抖动控制及抖动优化方法研究<sup>[4]</sup>,其中抖动识别是进行抖动控制和优化的基础。现有工业机器人抖动识别方法多进行工业机器人加工稳定性的监测,通过复杂的信号分析方法提取监测信号中具有能量分布变化的抖动特征,完成是否发生抖动的识别<sup>[5]</sup>。而工业机器人抖动原因识别时因工业机器人运动受各关节相互影响,需采集较长周期信号才能包含每个关节的运动状态信息,导致末端运动信号信息繁杂、冗余,常用的信号特征提取方法失效。

针对待测信号信息量大、特征复杂问题,通常采用有监督深度学习方法进行检测<sup>[6-7]</sup>。但该方法需足量标记样本,工业机器人抖动原因识别中受运动工况变化和关节耦合影响,抖动原因样本标记十分困难。而自监督学习是一种自动聚类方法,通过自主探索数据和特征结构的规律来解决机械故障诊断及运动状态识别的问题,尤其是在样本数据量大、有标签样本缺失的情况下<sup>[8]</sup>。自监督学习<sup>[9]</sup>分为生成式方法和对比式方法,其中动量对比学习(momentum contrast, MoCo)<sup>[10]</sup>使用深度网络结构作为正负编码器,从无标签训练数据中创建正样本队列及负样本字典,通过拉近正样本和推开负样本来最大化正负样本特征差异,并以动量参数更新完成聚类模型训练,具有强泛化性、高稳定性的优点,正逐步应用于故障诊断及运动状态识别。李巍华等<sup>[11]</sup>在 MoCo 的基础上调换正样本对数据使正负编码器进行两次损失计算,以对称对比学习的方式实现了齿轮箱数据自主聚类。Ding 等<sup>[12]</sup>和 Yan 等<sup>[13]</sup>通过 MoCo 对大量无标签数据进行预训练,并使用少量有标签数据进行微调,完成了滚动轴承故障诊断。

以上方法为识别与诊断提供了新思路,但进行工业机器人抖动原因识别仍存在如下 3 个问题:1) 样本需求量大,对比学习中负样本字典需尽可能大,促使正样本更

好地对比学习,若样本量较小,负样本字典占比过高,将导致正样本与字典中类别划分错误的假负样本对比次数增加,难以实现正负样本分离;2) 对比学习预训练+少量标签样本微调对预训练数据潜在信息分布有较高要求,且微调过程易使数据特征偏向局部;3) 工业机器人抖动位置及方向不确定,单传感器数据特征表达不完整。且工业机器人轨迹周期长,单样本数据庞大难以处理。

针对以上问题,提出基于数据融合和改进 MoCo 的工业机器人抖动原因识别方法。首先,对同一时间多通道传感器数据进行数据降维、滑动平移及随机加噪扩充样本,降低长周期数据冗余度同时提升数据多样性;通过水平拼接融合各通道样本并再次进行数据降维,展现完整的工业机器人抖动信息的同时约简训练样本。然后,在 MoCo 基础上为正负编码器设置双通道输出,少量有标签融合数据通过分类输出通道进行聚类引导,大量无标签融合数据通过特征对比输出通道进行对称中心对比学习。其中,对称中心对比学习通过正样本与负样本矩阵聚类中心进行对比,可降低负样本字典中假负样本的干扰,并通过调换正样本对进行两次对比学习,以充分利用无标签数据信息提升模型聚类性能。最后,将待测融合数据输入正编码器,通过分类通道及 Softmax 分类器输出工业机器人抖动原因识别结果。

## 1 工业机器人抖动原因融合样本构建

工业机器人抖动原因测试中,为保证运动轨迹信号包含所有关节运动信息和高频抖动信息,需设置较长采样周期及采样频率,因此待测时间序列具有数据量大、冗余度高的特点。并且在工业机器人运行过程中,不同方向的传感器将采集到不同的抖动状态信息,根据工业机器人实际运动轨迹变化其抖动状态信息将在不同时序片段及不同传感器方向上呈现。由于最大三角形三桶(largest triangle three Buckets, LTTB)<sup>[14]</sup>算法较其它数据降维方法能最大程度保留数据趋势,并显著降低数据量。因此所提方法以该降维方法降低数据冗余度提高数据处理及训练效率,并采用时序数据水平拼接融合方法,构建具有完整抖动方向及状态信息的工业机器人抖动原因融合样本。

### 1.1 LTTB 数据降维

LTTB 算法是基于时间序列的降维算法,通过选取数据中 3 个距离最大的点来进行重采样,从而实现数据维度的降低。

令原始数据长度为  $N$ , 数据降维后长度为  $n$ 。首先, 将数据按顺序分成  $n$  个桶, 其中首尾两个桶仅含第 1 及最后一个数据点, 其余桶的数据点数为  $(N - 2)/(n - 2)$ 。然后, 通过计算中间各桶所有的数据点与下一个桶的平均点及最后一个桶的数据点形成的三角形面积并选取最大面积作为该桶重采样点。最后, 将首尾两点及中间桶重采样点按顺序拼接获得降维数据。其中三角形面积通过海伦公式进行计算, 公式如下:

$$S = \sqrt{p(p - a)(p - b)(p - c)} \quad (1)$$

式中:  $S$  为三角形面积;  $p$  为三角形半周长;  $a, b, c$  为三角形边长。

## 1.2 时序数据水平拼接融合

为充分保留工业机器人抖动时间与空间上的信息, 将同一时间不同通道传感器时序按照水平拼接的方式融合。工业机器人抖动时序数据拼接融合方法流程如图 1 所示, 步骤如下: 1) 对各通道传感器时序数据进行 LTTB 数据降维, 提高数据预处理效率; 2) 通过时间维度均匀移动并添加随机噪声扩充各传感器通道样本; 3) 水平拼接各通道扩充时序样本, 得到具有多方向及完整周期信息的融合时序数据; 4) 对融合数据进行 LTTB 降维, 避免传感器数据拼接过多引起训练模型复杂度增加。

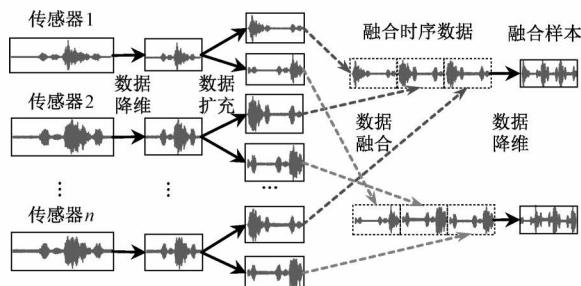


图 1 多传感器时序数据拼接融合

Fig. 1 Multiple sensor time series data fusion by concatenation

## 2 改进 MoCo 原理

### 2.1 双输出一维卷积神经网络(DO-1D-CNN)

DO-1D-CNN 是一种在 1D-CNN<sup>[15]</sup> 基础上设置两个线性输出层的深度学习网络。该网络不仅能通过一维卷积挖掘时间序列局部和全局依赖关系, 建立非线性映射, 而且可借助双输出通道在同一主干网络中进行两种特征学习任务, 建立双输出任务的联系。DO-1D-CNN 由输入层、卷积层、池化层、全连接层、双输出层组成, 网络结构如图 2 所示。

卷积层通过多个卷积核与输入数据进行卷积运算, 并使用批归一化 (batch normalization, BN) 优化特征表

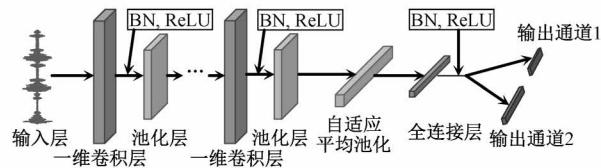


图 2 双输出一维卷积神经网络

Fig. 2 DO-1D-CNN

达、激活函数进行非线性特征提取。卷积运算公式为:

$$X^m = f((W^m * X^{m-1} + b^m)_{BN}) \quad (2)$$

式中:  $X^m$  为第  $m$  层输出;  $W^m$  为需更新的权重参数;  $b^m$  为偏置;  $(\cdot)_{BN}$  为批归一化操作;  $f(\cdot)$  为激活函数。由于 ReLU 激活函数计算效率高且不易出现梯度消失, 故选用该激活函数, 其表达式为:

$$f(x) = \max(x, 0) = \begin{cases} 0, & x < 0 \\ x, & x > 0 \end{cases} \quad (3)$$

池化层可通过下采样的方式对输入特征进行降维。其中卷积层后使用最大池化, 可通过减少空间维度特征, 降低计算成本。全连接层前选用自适应平均池化, 可通过聚合汇总特征重要信息, 防止过拟合。

全连接层将特征进行线性连接及组合, 并通过激活函数进行非线性转换。双输出则是通过线性连接整合全连接层信息, 并行输出分类特征及对比特征。

### 2.2 聚类引导和对称中心动量对比学习(CGSC-MoCo)

CGSC-MoCo 是在 MoCo 的基础上, 增加了有标签数据分类输出模块, 引导无标签数据特征聚类。修改了正负样本对比形式, 使其与负样本矩阵聚类中心进行对比, 降低假负样本的干扰。通过交换正样本队重复输入编码器对比学习更多自监督信息, 提升模型特征表达能力<sup>[11]</sup>。方法对比如图 3 所示。

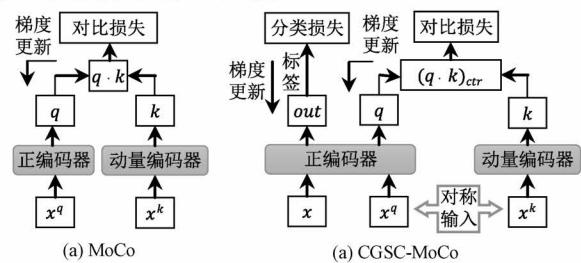


图 3 MoCo 与 CGSC-MoCo 方法对比

Fig. 3 MoCo and CGSC-MoCo method comparison

CGSC-MoCo 原理如下: 设置两个双输出编码器  $\theta_q$ 、 $\theta_k$ , 输出通道 1 输出分类特征和输出通道 2 输出对比学习特征,  $\theta_q$  参数通过损失计算进行更新,  $\theta_k$  则使用动量参数更新, 以使特征对比学习更稳定更具差异性。动量更新公式如下:

$$\theta_k = m\theta_k + (1 - m)\theta_q \quad (4)$$

式中:  $m \in [0,1)$  为动量更新参数。以下步骤的  $\theta_k$  均采用动量参数更新。

### 1) 数据增强

数据增强可为 CGSC-MoCo 提供不同的数据状态,确保模型学习到的特征对具有可比性和多样性,从而提高模型对于不同数据的适应性和泛化能力。所采用的一维数据增强方法有水平翻转、垂直翻转、随机加噪、标准化、随机置 0 及随机缩放。

### 2) 聚类引导

有标签数据经数据增强后输入编码器  $\theta_q$ ,通过输出通道 1 输出分类特征  $out$ ,结合  $label$  计算交叉熵损失并进行反向传播更新  $\theta_q$  参数,从而完成少量有监督数据的聚类引导。交叉熵损失公式如下:

$$loss1 = -\log \frac{\exp(out[label]/t_1)}{\sum_{i=1}^C \exp(out[i]/t_1)} \quad (5)$$

式中:  $C$  为标签类别总数;  $t_1$  为温度,可增大或缩小各个类别概率差距,提升模型拟合能力。

### 3) 对称中心对比学习

无标签数据通过不同数据增强得到  $x_1$  及  $x_2$ ,分别将其按批量  $N$  输入编码器  $\theta_q$  及  $\theta_k$  经输出通道 2 输出对比特征  $q$  及  $k$ 。负样本字典  $d$  为一个  $F \times L$  的矩阵,在完成单批量的对称中心对比学习后通过  $k$  更新旧字典。 $F$  为对比学习特征维度, $L$  为字典大小,为保证负样本更多对比更充分, $L$  大小与样本总数一致。

正样本相似度通过特征  $q$  与特征  $k$  点积相似度计算所得,其计算公式为:

$$Sim(q, k) = q \cdot k^T \leq 1 \quad (6)$$

式中:  $Sim(q, k)$  为正样本对相似度,其越接近 1 说明  $q$  与  $k$  越相似。

通过特征  $q$  与字典  $d$  点积计算得到  $N \times L$  的负样本对比矩阵,并以式(7)从小到大排列每个样本的对比相似

度。然后按顺序将样本对比相似度均匀划分为  $C$  组,并通过平均值计算得到负样本聚类中心。最后为降低假负样本的影响,去除相似度最高的聚类中心,获得代表正负样本相似度的中心矩阵。公式如下:

$$B_i = Sim(\mathbf{q}, \mathbf{d})[i] = argsort((\mathbf{q} \cdot \mathbf{d})[i]) \quad (7)$$

$$(q \cdot d)_{ctr}[i] = \frac{cat(\sum_{j=1}^{L/C} B_i[j], \dots, \sum_{j=(C-2)L/C+1}^{(C-1)L/C} B_i[j])}{L/C} \quad (8)$$

式中:  $argsort(\cdot)$  将元素从小到大进行排列; $i$  为批量为  $N$  的样本索引; $(\mathbf{q} \cdot \mathbf{d})_{ctr}$  为负样本中心矩阵; $j$  为个数为  $C-1$  的聚类中心索引; $cat(\cdot)$  为矩阵拼接。

CGSC-MoCo 的损失函数根据 MoCo 的 InfoNCE 进行改进,通过正样本点积矩阵与负样本中心矩阵进行对比,拉近正样本之间距离并远离负样本。其公式为:

$$loss2 = -\log \frac{\exp(q \cdot k/t_2)}{\sum_{i=1}^L \exp((q \cdot d)_{ctr}[i]/t_2)} \quad (9)$$

式中:  $t_2$  为对比学习的温度,其值应小于 1,可使对数更尖锐,从而增加正负样本的差异。

通过  $loss2$  更新参数后,将  $x_2$  输入编码器  $\theta_q$ 、 $x_1$  输入编码器  $\theta_k$ ,重复中心对比学习步骤,即可得到对称中心对比损失  $loss3$ ,从而完成对称中心对比学习训练。

## 3 工业机器人抖动原因识别流程

基于数据融合和 CGSC-MoCo 的工业机器人抖动原因识别流程如图 4 所示,具体步骤如下。

1) 工业机器人周期轨迹信号采集及数据预处理,通过三向加速度传感器同步采集工业机器人末端周期轨迹振动信号,将所有通道信号进行数据降维、扩充、融合、降维操作并标定少量样本的标签,获得融合训练样本。测试样本进行数据降维、融合、降维操作即可。

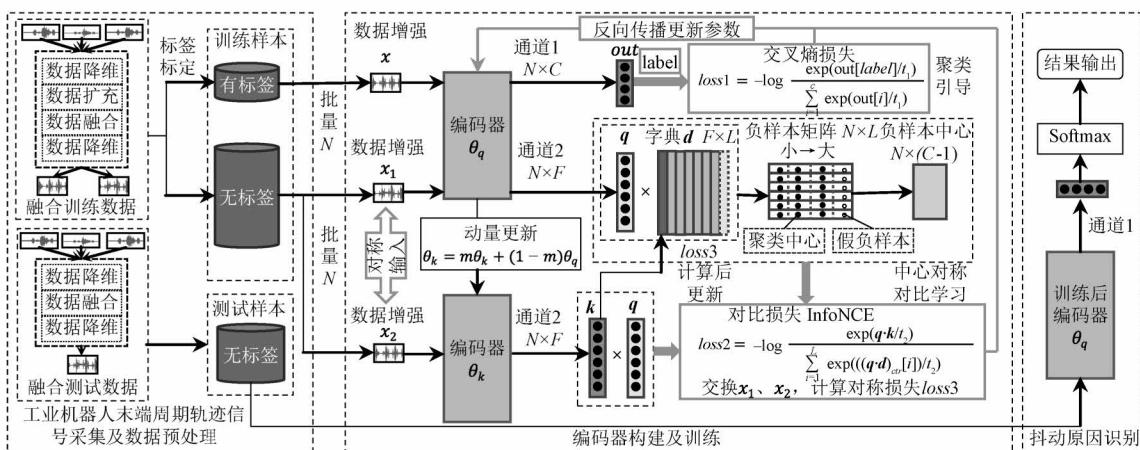


图 4 数据融合和 CGCS-MoCo 的工业机器人抖动原因识别流程

Fig. 4 Data fusion and CGCS-MoCo industrial robot jitter cause recognition process

2) 构建两个初始化参数一致的双输出编码器  $\theta_q, \theta_k$ , 初始化一个  $F \times L$  的负样本字典。将少量有标签数据经数据增强后, 输入编码器  $\theta_q$ , 由通道 1 输出分类特征。结合  $label$  计算交叉熵损失并更新  $\theta_q, \theta_k$  进行动量更新, 从而完成聚类引导。

3) 将大量无标签数据通过不同的数据增强方式获得  $x_1, x_2$ 。将其分别输入  $\theta_q$  和  $\theta_k$  中, 由通道 2 输出对比特征  $q$  与  $k$ 。正样本对比相似度通过  $q$  和  $k$  点积计算获得。通过  $q$  与  $d$  点积计算、排序求平均得到各样本的聚类中心, 并去除假负样本中心、重新组合得到具有正负样本相似度信息的负样本中心矩阵。通过 InfoNCE 计算对比损失并更新  $\theta_q$ , 动量更新  $\theta_k$ , 完成中心对比学习。

4) 交换  $x_1, x_2$ , 重复步骤 3), 然后使用该步骤对比特征  $k$  逐步更新字典  $d$ , 完成对称中心对比学习。

5) 经过多次迭代充分学习得到训练后编码器  $\theta_q$ , 输入测试样本, 通过通道 1 输出分类特征, 结合 softmax 分类器即可得到识别结果。

## 4 实验验证

### 4.1 数据采集

实验数据采集自型号为 JH612 的工业机器人, 测试传感器为三向加速度传感器, 安装位置如图 5 所示。工业机器人实验轨迹根据 GB/T 12642-2013 设置为圆形轨迹, 执行该轨迹时各关节均需运动。为保证安全, 轨迹运行速度为满转速的 10%、30%、50%。通过调节各关节控制参数可得, 关节 1、关节 2、关节 3、关节 4、关节 5、关节 6 引起抖动和正常 7 种抖动状态。

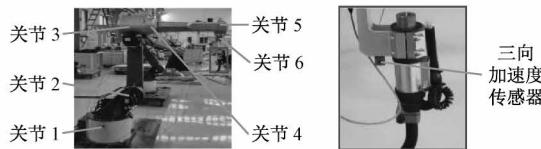


图 5 三向加速度传感器安装位置

Fig. 5 Three-axis acceleration sensor installation position

实验采样频率为 10 240 Hz, 各转速每种运动状态采集 30 组数据。按 22:2:6 的比例随机划分为无标签训练数据、有标签训练数据及测试数据。各通道振动信号数据降维后长度为 2 048。为增加训练及测试样本多样性, 训练集及测试集均进行 10 倍数据扩充。时间同步且包含三向加速度所有通道的融合数据降维后长度为 3 072。训练及测试样本组成如表 1 所示。

表 1 工业机器人抖动原因数据集

Table 1 Industrial robot end-jitter cause dataset

编号	引起抖动原因	训练样本		测试样本
		无标签	有标签	
A	正常	220	20	60
B	关节 1	220	20	60
C	关节 2	220	20	60
D	关节 3	220	20	60
E	关节 4	220	20	60
F	关节 5	220	20	60
G	关节 6	220	20	60
合计		1 540	140	420

### 4.2 参数设置

为适应计算资源受限的环境和减少深层网络过拟合风险, 编码器选用较浅的 3 层 DO-1D-CNN, 分别有 128、256、512 个卷积核, 卷积核大小均为  $3 \times 1$ , 步长为 1; 最大池化层大小为  $2 \times 1$ , 步长为 2; 使用一个 256 维的全连接层, 输出 1 的  $C$  设置为 7, 输出 2 的  $F$  设置 128。训练优化器采用 SGD, 使用余弦退火学习率, 最大为 0.02, 最小为  $10^{-4}$ , 学习率动量为 0.9, 权重衰减为  $10^{-4}$ , 批量  $N$  为 64, 迭代轮数为 100。聚类引导温度  $t_1$  为 0.1, 对比学习温度  $t_2$  为 0.07, 编码器动量为 0.999。以下实验均在 CPU 为 AMD Ryzen 7 5800H, GPU 为 6 GB 显存的 NVIDIA GeForce RTX 3060, 内存为 16 GB, Python3.7.1 上的 Pytorch1.8.1 的环境下进行。所使用的显存为 6 GB, 计算资源消耗较小, 硬件要求低。

一维数据增强有水平翻转、垂直翻转、随机添加 0~0.2 倍高斯白噪声、标准化、25% 数据随机置 0 及随机缩放 0.5~2 倍。每个训练样本任选其一进行数据增强。

### 4.3 评价指标

分类准确率可衡量对比学习下游任务的好坏, 聚类引导方法的分类准确率可通过输出 1 直接计算可得, 自监督方法则通过有标签数据微调 30 轮获取, 分类准确率为测试数据后 5 轮平均值。

将输出层前 256 维特征通过 t-SNE 降维, 得到二维特征。并通过轮廓系数 (silhouette coefficient, SC)、划分系数 (partition coefficient, PC) 及划分熵 (classification entropy, CE) 衡量聚类结果的紧密度和分离度。SC 取值范围在  $[-1, 1]$  之间, 值越接近 1, 表示聚类效果越好。

$$SC = \frac{1}{L} \sum_{i=1}^L \frac{b_i - a_i}{\max(a_i, b_i)} \quad (10)$$

式中:  $L$  为样本数;  $b_i$  为第  $i$  个样本与同类样本的平均欧氏距离;  $a_i$  为与其它类所有点平均距离的最小值。

$PC$  越接近 1, 表示类别内部紧密度越好;  $CE$  越接近 0, 表示类别间分离度越好。公式如下:

$$PC = \frac{1}{L} \sum_{i=1}^L \sum_{j=1}^c u_{ij}^2 \quad (11)$$

$$CE = -\frac{1}{L} \sum_{i=1}^L \sum_{j=1}^c u_{ij} \log(u_{ij}) \quad (12)$$

式中:  $c$  为分类数;  $u_{ij}$  由模糊 C 均值聚类算法计算得到, 表示第  $i$  个样本属于  $j$  类的隶属度。

#### 4.4 实验结果及分析

为验证数据融合和 CGSC-MoCo 的工业机器人抖动原因识别方法有效性, 在工况为 10% 满转速下进行实验。将所提方法与各通道数据和 CGSC-MoCo 结合的  $X$  通道、 $Y$  通道、 $Z$  通道方法对比, 及进行数据融合, 与对称式 MoCo<sup>[11]</sup>、MoCo<sup>[12]</sup>、少量样本有监督、全样本有监督方法进行对比。表 2 为不同方法的识别及聚类结果, 所有训练数据的 t-SNE 特征可视化结果如图 6 所示。

表 2 不同方法的识别及聚类结果

Table 2 Recognition and clustering results of different methods

方法	分类准确率/%	SC	PC	CE
本文	<b>98.71±0.33</b>	<b>0.962 0</b>	<b>0.899 8</b>	<b>0.274 4</b>
$X$ 通道	89.95±1.00	0.474 4	0.838 9	0.394 8
$Y$ 通道	88.19±1.76	0.523 2	0.752 7	0.568 0
$Z$ 通道	91.33±3.43	0.761 6	0.824 4	0.435 0
对称式 MoCo	91.48±1.14	0.837 3	0.810 7	0.456 3
MoCo	89.67±0.86	0.812 6	0.808 5	0.434 9
少量样本有监督	80.10±6.57	0.601 2	0.751 4	0.571 3
全样本有监督	99.38±0.33	0.957 7	0.893 3	0.289 9

由表 2 看出, 本文方法与  $X$  通道、 $Y$  通道、 $Z$  通道方法进行对比, 准确率可提升 7% 以上,  $SC$ 、 $PC$ 、 $CE$  指标均具有明显优势, 说明融合数据蕴含了工业机器人各方向运动信息, 可全面反映抖动状态。由图 6(a)~(d) 可知, A(正常) 与 B(关节 1 引起抖动) 在  $X$  通道中难以分离, 但在  $Y$  通道及  $Z$  通道中均实现了分离, 故融合数据通过学习  $Y$ 、 $Z$  方向上 A、B 两类自监督信息实现了有效聚类。

表 2 中少量样本有监督方法由于训练样本过少, 学习到的监督信息不足, 导致其在融合数据中样本聚类效果不佳, 分类准确率仅为 80.1%, 且波动较大难以收敛。全样本有监督因其样本及标签充足有足够的监督信息, 故其能实现各类别数据的分离。所提方法准确率及聚类指标与全样本方法相当, 且明显优于少量样本监督方法, 说明所提方法可借助微弱的有监督信息引导对比学习进行自监督信息的学习, 实现有效聚类。

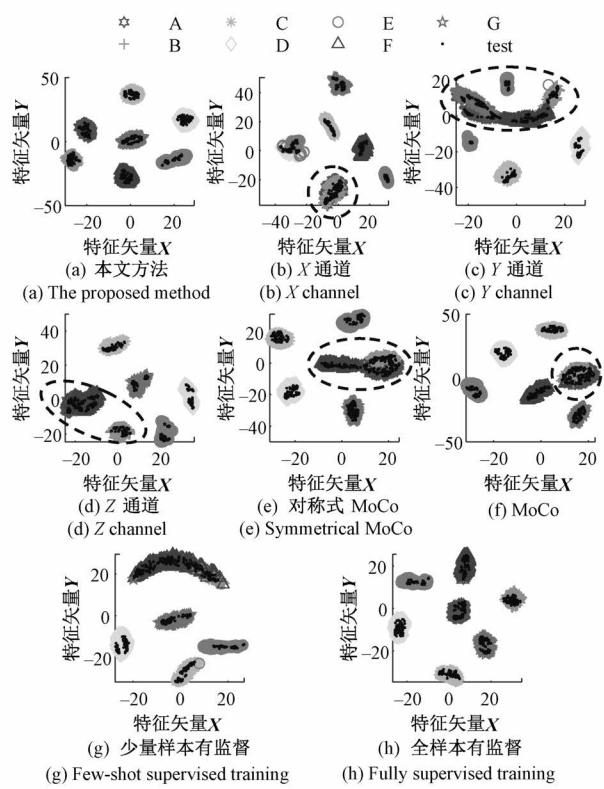


图 6 不同方法特征可视化对比

Fig. 6 Comparison feature visualization of different methods

对称式 MoCo 及 MoCo 两种方法, 虽然学习了样本间可分离的自监督信息及少量微调样本的有监督信息, 优于少量样本有监督方法。但其在对比学习中, 忽略了假负样本的影响, 易出现自监督信息的混乱, 由图 6(e)、(f) 可知, 未融合数据易出现混淆的 AB 两类难以实现分离。且需进行预训练和微调两个步骤, 实际应用相对繁琐。

综上所述, 所提方法通过数据增强全面反映工业机器人抖动方向及状态信息, 通过 CGSC-MoCo 充分学习信号自监督信息并对比 C-1 个负样本中心排除假负样本的干扰, 分类准确率高达 98.71%,  $SC$ 、 $PC$ 、 $CE$  指标均为最优, 说明了所提方法是有效的、可行的。且训练完成后编码器可直接进行识别, 应用更加便捷。

为进一步分析所提方法的 CGSC-MoCo 结构特征聚类的效果, 将 CGSC-MoCo 结构与对称+中心 MoCo、聚类引导+对称 MoCo、聚类引导+中心 MoCo 进行消融实验对比。采用工况为 10% 满转速下的融合数据进行实验, 将输入特征进行 t-SNE 降维得到原始特征分布情况。不同结构识别结果及特征聚类效果如表 3、图 7 所示。

观察表 3 及图 7(a)、(b) 可知, CGSC-MoCo 可将杂乱的融合数据输入特征进行很好的聚类, 其中  $SC$  为 0.962 0、 $PC$  为 0.899 8、 $CE$  为 0.274 4, 3 种指标为 4 种

**表3 不同结构识别结果**  
**Table 3 Recognition results of different structures**

方法	分类准确率/%	SC	PC	CE
融合数据输入特征	-	-0.193 9	0.419 7	1.265 6
CGSC-MoCo	<b>98.71±0.33</b>	<b>0.962 0</b>	<b>0.899 8</b>	<b>0.274 4</b>
对称+中心 MoCo	96.71±3.14	0.899 7	0.850 9	0.370 6
聚类引导+对称 MoCo	95.81±2.48	0.906 6	0.848 3	0.377 8
聚类引导+中心 MoCo	91.05±1.29	0.915 9	0.859 3	0.352 4

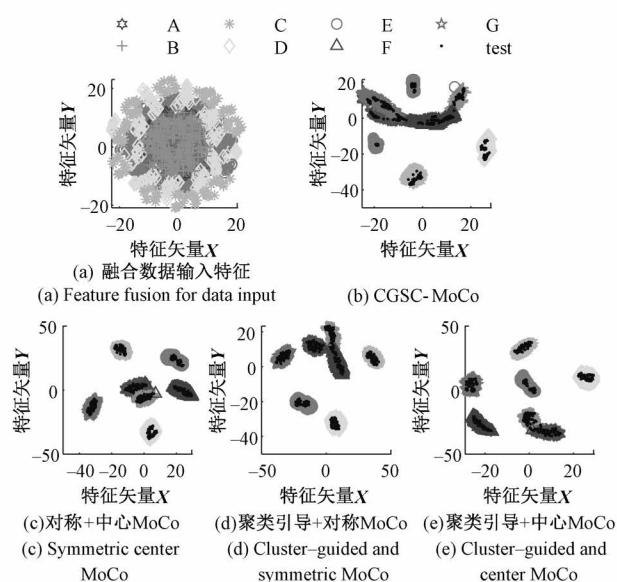


图7 不同结构特征可视化对比

Fig. 7 Comparing feature visualization of different architectures

对比结构的最优值,说明CGSC-MoCo结构对类间特征具有很好的分离度且类内具有很好的紧密型。其原因为聚类引导结构通过有监督信息引导类间进行分离聚类;中心对比结构通过正样本与负样本中心进行对比,拉远了类间距离,并减少了假负样本对比导致类间距不紧密的问题;而对称训练结构提升了聚类稳定性。

表3中对称+中心MoCo结构较于CGSC-MoCo分类准确率降低了2%,图7(c)中A、B两类与图6(g)类似难以分离。微调易出现少量样本过度学习导致结果偏向局部,致使识别率降低。而聚类引导通过与对比学习参数更新交替运行,能让编码器对有监督及自监督信息自动取舍,避免局部最优。

聚类引导+对称MoCo结构由于缺少聚类中心信息及假负样本过滤,导致图7(d)A、B、F 3类分类性能不佳,其PC值较低类内紧密型较差,CE值较高类间分离度低。

聚类引导+中心MoCo结构由于缺少对称训练结构,未充分利用自监督信息对有监督特征进行调整,致使训练稳定性、泛化性降低。其分类准确率较于CGSC-MoCo下降了7.66%。

最后为验证所提方法的稳健性,在30%满转速及50%满转速的工况下进行实验,表4为所提方法与其它方法在不同工况下对比实验结果。

表4 不同工况的识别结果

Table 4 Recognition results of different operating conditions

工况	方法	分类准确率/%		
		SC	PC	CE
30%	本文方法	<b>92.76±1.10</b>	<b>0.855 6</b>	<b>0.872 8</b>
	融合数据输入特征	-	-0.131 4	0.458 1
	X通道	89.52±0.71	0.589 3	0.825 7
	Y通道	90.10±1.10	0.728 4	0.839 5
	Z通道	89.48±3.76	0.790 5	0.858 3
满转速	对称式MoCo	82.43±0.67	0.724 6	0.780 8
	MoCo	80.67±0.52	0.765 8	0.817 9
	少量样本有监督	59.10±5.43	0.700 7	0.802 1
	全样本有监督	99.95±0.19	0.971 8	0.917 1
	对称+中心MoCo	88.71±1.33	0.818 2	0.821 9
	聚类引导+对称MoCo	84.43±2.52	0.721 4	0.777 9
	聚类引导+中心MoCo	85.48±3.10	0.794 9	0.798 7
50%	本文方法	<b>93.24±0.81</b>	<b>0.852 0</b>	<b>0.875 9</b>
	融合数据输入特征	-	-0.045 2	0.493 8
	X通道	80.29±1.14	0.543 2	0.756 4
	Y通道	83.71±0.38	0.648 4	0.735 9
	Z通道	81.00±1.14	0.579 7	0.841 2
满转速	对称式MoCo	82.43±0.67	0.724 6	0.780 8
	MoCo	80.67±0.52	0.765 8	0.817 9
	少量样本有监督	62.76±5.14	0.773 3	0.837 0
	全样本有监督	99.19±1.33	0.963 1	0.918 6
	对称+中心MoCo	88.71±1.33	0.818 2	0.860 6
	聚类引导+对称MoCo	89.43±2.76	0.673 2	0.798 0
	聚类引导+中心MoCo	86.19±1.90	0.751 0	0.786 3

观察表4可知,由于实验转速升高,工业机器人由关节控制不佳引起的抖动易被本身运动惯性所掩盖,导致自监督信息不明显,故30%和50%满转速工况准确率分别为92.76%、93.24%,略低于10%满转速情况。两种工况下准确率仅低于全样本有监督方法,但所提方法无需大量标记样本,可有效降低有监督学习标签标记工作量。所提方法较于未融合数据、预训练+微调、CGSC-MoCo消

融结构方法,实验准确率及 $SC$ 、 $PC$ 、 $CE$ 评价指标均有明显优势,说明所提方法在不同工况工业机器人抖动原因识别中具有较好的稳健性。

## 5 结 论

一维数据水平拼接融合通过对多方向传感器振动信号进行LTTB数据降维、平移加噪扩充、水平拼接融合及数据再降维操作,有效降低了工业机器人轨迹周期信号冗余度、提升了数据多样性及抖动方向全面性。且水平拼接融合与数据降维结合,可为更多传感器通道融合或更多时序信号源数据融合提供方案。

CGSC-MoCo中双输出编码器的设置可建立聚类与对比特征学习的联系,可在对比学习完后直接进行工业机器人抖动原因识别;聚类引导能平衡有监督及自监督信息,引导编码器找到全局聚类特征;中心对比学习结构能降低假负样本干扰,提升类间分离度、类内紧密性;对称训练能让编码器学习到更多自监督信息,提升了对比学习稳定性及编码器识别准确率。

本文所提方法工况适应性强,实现了端到端的工业机器人抖动原因识别,可为抖动关节定位及调节控制参数抑制抖动提供指导建议。

## 参考文献

- [1] 孙立宁,许辉,王振华,等.工业机器人智能化应用关键共性技术综述[J].振动·测试与诊断,2021,41(2):211-219,406.  
SUN L N, XU H, WANG ZH H, et al. Review on key common technologies for intelligent applications of industrial robots[J]. Journal of Vibration Measurement & Diagnosis, 2021, 41(2): 211-219, 406.
- [2] LI Z B, LI S, LUO X. An overview of calibration technology of industrial robots[J]. IEEE/CAA Journal of Automatica Sinica, 2021, 8(1): 23-36.
- [3] 李琳,古智超,张铁.结合机器人柔体动力学和关节力矩反馈的振动控制[J].振动与冲击,2022,41(11):235-244.  
LI L, GU ZH CH, ZHANG T. Vibration control of robot to combine flexible body dynamics and joint torque feedback[J]. Journal of Vibration and Shock, 2022, 41(11): 235-244.
- [4] 廖文和,郑侃,孙连军,等.大型复杂构件机器人加工稳定性研究进展[J].航空学报,2022,43(1):164-183.  
LIAO W H, ZHENG K, SUN L J, et al. Review on chatter stability in robotic machining for large complex components [J]. Acta Aeronautica et Astronautica Sinica, 2022, 43(1): 164-183.
- [5] 薛雷,曾宏伟,覃程锦,等.采用同步压缩变换和能量熵的机器人加工颤振监测方法[J].西安交通大学学报,2019,53(8):24-30,89.  
XUE L, ZENG H W, QIN CH J, et al. A chatter monitoring method for robotic machining using synchro-squeezed transform and energy entropy[J]. Journal of Xi'an Jiaotong University, 2019, 53(8): 24-30, 89.
- [6] 赵威,王锴,徐皓冬,等.面向智能制造的工业机器人健康评估方法[J].机器人,2020(4):460-468.  
ZHAO W, WANG K, XU AI D, et al. An industrial robot health assessment method for intelligent manufacturing[J]. Robot, 2020(4): 460-468.
- [7] LONG J, QIN Y, YANG Z, et al. Discriminative feature learning using a multiscale convolutional capsule network from attitude data for fault diagnosis of industrial robots[J]. Mechanical Systems and Signal Processing, 2023, 182: 109569.
- [8] LI X, LI X, MA H. Deep representation clustering-based fault diagnosis method with unsupervised data applied to rotating machinery[J]. Mechanical Systems and Signal Processing, 2020, 143: 106825.
- [9] LIU X, ZHANG F, HOU Z, et al. Self-supervised learning: Generative or contrastive [J]. IEEE Transactions on Knowledge and Data Engineering, 2021, 35(1): 857-876.
- [10] HE K, FAN H, WU Y, et al. Momentum contrast for unsupervised visual representation learning [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 9729-9738.
- [11] 李巍华,何琛,陈祝云,等.基于对称式对比学习的齿轮箱无监督故障诊断方法[J].仪器仪表学报,2022,43(3):121-131.  
LI W H, HE CH, CHEN ZH Y, et al. Unsupervised fault diagnosis of gearbox based on symmetrical contrast learning[J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 121-131.
- [12] DING Y, ZHUANG J, DING P, et al. Self-supervised pretraining via contrast learning for intelligent incipient fault detection of bearings[J]. Reliability Engineering & System Safety, 2022, 218: 108126.

- [13] YAN Z, LIU H. SMoCo: A powerful and efficient method based on self-supervised learning for fault diagnosis of aero-engine bearing under limited data [J]. Mathematics, 2022, 10(15): 2796.
- [14] STEINARSSON S. Downampling time series for visual representation [D]. Iceland: Mechanical Engineering and Computer Science University, 2013.
- [15] WANG J, WANG D, WANG X. Fault diagnosis of industrial robots based on multi-sensor information fusion and 1D convolutional neural network [C]. 39th Chinese Control Conference (CCC), 2020: 3087-3091.

#### 作者简介



陈仁祥(通信作者),分别在2007年和2012年于重庆大学获得学士学位和博士学位,现为重庆交通大学教授、博士生导师,主要研究方向为智能测试技术与信号处理。  
E-mail: manlou.yue@126.com

**Chen Renxiang** (Corresponding author) received his B. Sc. and Ph. D. degrees both from Chongqing University in 2007 and 2012, respectively. He is currently a professor and a Ph. D. supervisor at Chongqing Jiaotong University. His main research interests include intelligent testing technology and signal processing.



谢文举,2020年于重庆交通大学获得学士学位,现为重庆交通大学硕士研究生,主要研究方向为工业机器人健康状态评估。

E-mail: 929294593@qq.com

**Xie Wenju** received his B. Sc. degree from Chongqing Jiaotong University in 2020. He is currently a M. Sc. candidate at Chongqing Jiaotong University. His main research interests include Health status evaluation of industrial robots.