

# 基于多传感器信息融合与混合感受野残差卷积神经网络的调相机转子故障诊断

钱白云<sup>1</sup>, 吕朝阳<sup>2</sup>, 张维宁<sup>3</sup>, 林翔<sup>1</sup>, 朱霄珣<sup>2</sup>, 董利江<sup>4</sup>,  
吴玉华<sup>1</sup>, 王鲁东<sup>1</sup>, 李震涛<sup>2</sup>

(1. 国网新疆电力有限公司电力科学研究院, 乌鲁木齐 830000;

2. 华北电力大学 动力工程系, 河北 保定 071003;

3. 国网新疆电力有限公司, 乌鲁木齐 830000;

4. 新疆新能集团有限责任公司乌鲁木齐电力建设调试所, 乌鲁木齐 830000)

**摘要:** 大型调相机是电网对无功调节的关键设备之一, 预防调相机因转子故障而产生的安全事故极为重要; 为了有效利用设备实际监测过程中多源传感器同步采集的海量数据, 并考虑传统卷积神经网络(CNN, convolutional neural network)模型的特征学习能力差、感受野尺度单一等缺点, 提出了一种基于SDP-MRFRCNN的调相机转子故障诊断方法; 首先通过对称点模式(SDP, symmetrized dot pattern)将调相机多个传感器的振动信号进行信息融合, 获取融合多源振动信息的图像, 然后构建混合感受野残差卷积神经网络(MRFRCNN, mixed receptive field residual CNN)进行学习, 实现调相机转子状态识别; 实验结果表明, 该方法增强了不同状态特征间的辨别度, 具有更高识别精度, 分类准确率达到99.33%。

**关键词:** 调相机; 转子振动; 多传感器融合; 卷积神经网络; 多感受野; 残差结构

## Fault Diagnosis of Synchronous Condenser Rotor Based on Multi-sensor Information Fusion and Mixed Receptive Field Residual Convolutional Neural Network

QIAN Baiyun<sup>1</sup>, LÜ Zhaoyang<sup>2</sup>, ZHANG Weining<sup>3</sup>, LIN Xiang<sup>1</sup>, ZHU Xiaoxun<sup>2</sup>,  
DONG Lijiang<sup>4</sup>, WU Yuhua<sup>1</sup>, WANG Ludong<sup>1</sup>, LI Zhentao<sup>2</sup>

(1. Electric Power Research Institute of Xinjiang Power Grid Corporation, Urumchi 830000, China;

2. Department of Power Engineering, North China Electric Power University, Baoding 071003, China;

3. State Grid Xinjiang Electric Power Co., Ltd., Urumchi 830000, China;

4. Urumqi Electric Power Construction and Commissioning Institute of Xinjiang Xinneng Group Co., Ltd., Urumchi 830000, China)

**Abstract:** A large-scale synchronous condenser is one of the key equipment with reactive power regulation in power grid. It is very important to prevent the safety accident of synchronous condenser caused by rotor failure. In order to effectively use the massive data synchronously collected by multi-source sensors in the actual monitoring process of the equipment, and considering the shortcomings of traditional convolutional neural network (CNN) models such as poor feature learning ability and single scale of receptive field, a fault diagnosis method of synchronous condenser rotor based on symmetrized dot pattern and mixed receptive field residual convolutional neural network (SDP-MRFRCNN) is proposed. Firstly, the vibration signals of multiple sensors of the synchronous condenser are fused by the symmetrized dot pattern (SDP) to obtain the image fused with multi-source vibration information. Then, the MRFRCNN is constructed to learn and realize the rotor status recognition of the synchronous condenser. The experimental results show that this method enhances the discrimination between different state features, and it has higher recognition accuracy, with an average classification accuracy of 99.33%.

收稿日期: 2022-10-21; 修回日期: 2023-01-09。

基金项目: 国家电网有限公司科技项目资助(SGXJDK00NYJS2200102)。

作者简介: 钱白云(1982-), 男, 大学本科, 高级工程师。

通讯作者: 朱霄珣(1985-), 男, 博士。

引用格式: 钱白云, 吕朝阳, 张维宁, 等. 基于多传感器信息融合与混合感受野残差卷积神经网络的调相机转子故障诊断[J]. 计算机测量与控制, 2023, 31(9): 29-35.

**Keywords:** synchronous condenser; rotor vibration; multi-sensor fusion; CNN; mixed receptive field; residual structure symmetrized dot pattern)

## 0 引言

如今风电、光伏等新能源正在大量并网，特高压直流输电技术也在不断发展，电网对无功调节的需求正在逐步提升。调相机作为大型无功调节设备，其无功增加能力与无功吸收能力均较强，可以在电网中增强电压的动态调节能力<sup>[1-3]</sup>，凭借出色的动态无功补偿能力，调相机能够消除电力系统电压突然提高带来的不良影响，尤其在网侧，调相机能够快速、大量的吸收换相失败产生的无功功率，同时对无功进行快速补偿，保障系统无功的稳定<sup>[4]</sup>。因此，调相机的安全稳定运行尤其关键。

调相机作为一种典型的旋转机械设备，转子是其最主要的组成部分，若发生故障会导致机组停机，产生较大的经济损失，甚至威胁人身安全<sup>[5-6]</sup>。因此，针对调相机转子进行准确快速的智能故障诊断，对提升机组的安全性和经济性具有十分重要的意义。对于大型旋转机械设备而言，振动传感器布置测点丰富、经济性、准确性较高，因此针对振动信号进行分析是一种普遍的状态监测方法。目前国内外学者尝试在转子、轴承等旋转机械的故障诊断中分析振动信号的特征。文献 [7] 通过改进经验模态分解 (EMD, empirical mode decomposition) 对转子振动信号进行分析，有效定位了转子故障特征。文献 [8] 通过联合定子振动特性与磁密谐波的综合特征，实现了大型调相机转子偏心故障的识别。文献 [9] 提出一种可调品质因子小波变换方法，识别了早期轴承故障。然而转子振动信号的故障特征相对更微弱，极易被现场噪声或其他无关信号淹没，进而影响到对转子运行状态的判断。

随着数据挖掘和人工智能技术的不断发展，信号特征提取结合传统机器学习模型实现故障诊断的方法被广泛研究，如：人工神经网络 (ANN, artificial neural network)、支持向量机 (support vector machines, SVM)、模糊识别<sup>[10-11]</sup>等。然而，实际工作时，设备工况经常发生变化，且许多信号特征提取方法无法在现场强噪声、多源干扰下分离并捕捉故障特征，同时浅层机器学习模型学习深度不足，在面临如今海量的工业数据时，此类方法的应用范围和诊断效果将受到制约<sup>[12]</sup>。

深度学习 (DL, deep learning) 的出现解决了信号处理方法特征提取能力有限和浅层机器学习学习中学习深度的问题<sup>[13]</sup>。而卷积神经网络 CNN 作为 DL 的一种特殊结构形式，是计算机视觉领域最强大的模型，因此最近受到了故障诊断领域研究人员的广泛关注<sup>[14]</sup>。文献 [15] 将原始信号转化为 AE 声谱图特征，结合 CNN 实现了转子碰摩故障的识别。文献 [16] 采用短时傅里叶变换将振动信号转化为时频图输入 CNN，实现了滚动轴承的故障诊断。文献 [17] 通过希尔伯特变换 (HT, Hilbert transform) 处理原始振动信号，并采用 PSO 算法对 CNN 参数进行优化，识

别了 5 种转子故障。另外，多个传感器捕获的信号包含系统运行的更多信息。在过去几年里，基于 CNN 的多传感器数据信息的融合策略也被广泛应用于全面描述旋转机械设备状态，利用多传感器数据所具有的同步关联性，有助于提高模型诊断准确率和抗噪声干扰能力<sup>[18-19]</sup>，合理利用多传感器信息且实现准确、快速诊断是需要重点关注的。

调相机转子和其它旋转设备的转子在基本机械结构原理上相似，均是将转子固定在转轴上，两端以轴承承托，但调相机设备的整体复杂程度决定了其转子结构相对复杂，其特点如下：大型调相机尺寸和重量大，工作转速跨越二阶临界转速，振型复杂，对运行工况和运行参数的变化敏感，因此调相机随不同运行条件具有多种振动状态。除此之外，其定转子上均有励磁绕组，振动并非单一的机械场，而是电磁—机械场相互耦合作用发生的结果，并且由于它的暂态反应能力和暂态过载能力强，导致其转子转速高，急起急停，内部温度场复杂多变，也会影响转子的振动状态。固使用通常转子故障诊断方法对调相机转子进行诊断，无法取得理想效果。

目前基于传统深度学习的转子故障诊断方法的优化主要以复杂化模型结构加深学习深度，但卷积神经网络的卷积、池化层堆叠，缺乏对故障特征不同尺度方向提取的考虑，并且过于复杂的模型堆叠会降低训练速度、耗费大量算力。从提高训练速度、分类精度和模型适应振动信号多尺度特性的角度，如何将数据可视化和分尺度特征提取与模型特征学习能力增强三者相结合是本文创新性研究的切入点。

基于以上研究，本文提出一种基于多传感器信息融合 SDP 图像联合多尺度 CNN 的调相机转子故障诊断方法。首先，基于使用对称点模式 (SDP, Symmetrized dot pattern,) 对调相机多个传感器的振动信息进行整体特征融合，以更全面的映射出识别对象的特征；在此基础上，构建混合感受野残差卷积神经网络 (MRFCNN, Multi receptive field CNN)，采用不同感受野的多尺度卷积核对 SDP 图进行全局特征学习。

## 1 对称点模式 SDP

SDP 算法可将复杂时间序列以散点的形式清晰映射在极坐标图中，可以使原始时域信号通过图形化的方式提高可视化能力<sup>[20]</sup>。因为极坐标图像的特殊性，多源信息可通过 SDP 方法融合在有限区域中。

在极坐标中  $x_i$  与  $x_{i+1}$  分别为时域信号中  $i$  时刻和  $i+1$  时刻的幅值，原信号通过 SDP 方法可变成极坐标空间  $s[r(i), \theta(i), \varphi(i)]$  中的点，上述变量的计算公式为：

$$r(i) = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (1)$$

$$\theta(i) = \theta + \frac{x_{i+1} - x_{min}}{x_{max} - x_{min}} \zeta \quad (2)$$

$$\varphi(i) = \theta - \frac{x_{i+1} - x_{\min}}{x_{\max} - x_{\min}} \zeta \quad (3)$$

其中:  $x_{\max}$  和  $x_{\min}$  分别为原始时域波形信号的最大振幅和最小振幅;  $\theta(i)$  和  $\varphi(i)$  分别为点对于镜像对称面而言, 沿逆时针和顺时针方向偏转的角度;  $r(i)$  为点的极径;  $\theta$  为规定的镜像对称面的偏转角度 ( $\theta = 360 m/n, m = 1, 2, \dots, n$ );  $\zeta$  为增益系数 ( $\zeta < \theta$ ), SDP 算法基本原理如图 1 所示。




图 1 SDP 基本基本原理

一维信号经 SDP 变化后, 可得到“花瓣状”的散点图, 避免了传统信号处理方法导致的数据压缩与特征丢失。而不同类别的信号间的差异主要表现在: 1) 散点花瓣的曲率; 2) 散点分布和形状特征; 3) 几何中心位置。在同一极坐标系中, 在不同象限可实现多个信号的信息融合, 更加凸显差异性。

## 2 混合感受野残差卷积神经网络 MRFCNN

### 2.1 卷积神经网络 CNN 概述

卷积神经网络 CNN 可以从数据中自动学习并提取抽象的深度特征信息, 在图像识别领域具有巨大潜力。CNN 对输入样本数据进行逐层卷积与池化, 具有一定的旋转、平移不变性, 被广泛应用于科研和工程领域。传统 CNN 包含卷积层、池化层、全连接层等, 以下对 CNN 主要操作进行概述。

给定第  $l-1$  层的输入, 则下一层的特征图为, 对应的卷积层操作如下:

$$y_i^l = \text{ReLU} \left( \sum_{j=1}^N y_j^{l-1} * k_{ij}^l + b_j^l \right) \quad (4)$$

其中,  $N$  为第  $l-1$  层卷积核数量,  $k_{ij}^l$  为  $l$  层中第  $i$  个特征图的第  $j$  个卷积核,  $b_j^l$  为偏置,  $\text{ReLU}(\cdot)$  为线性整流单元激活函数。

传统 CNN 中, 池化层会对每一个卷积层提取到的数据进一步降维, 加快计算速度且可以避免过拟合<sup>[21]</sup>。

经过多层学习, 原始数据信息初步被抽象成更高级的特征, 在网络的末尾 ( $L$  层) 由全连接层 (FC) 实现网络的最终分类, 全连接操作如下:

$$z^L = \sigma(\omega^L y^{L-1} + b^L) \quad (5)$$

其中,  $y^{L-1}$  为  $L-1$  层的神经元组,  $z^L$  为  $L$  层的神经元组,  $\omega^L, b^L$  分别为全连接层的权重和偏置。对于多分类问题, 全连接输出层激活函数为 Softmax, 通过有监督学习方式和反向传播算法进行训练, 利用梯度下降法, 经历多次

迭代使损失函数 Loss 值达到小, 从而完成训练。

不同的卷积核对图像信息的捕捉不同, 而通常情况下, 卷积核越大, 感受野 (receptive field) 越大, 看到的整体信息越多, 捕捉的全局特征越好, 但会导致计算量的激增。反之, 卷积核越小, 感受野越小, 获得的局部信息会更加具体。

调相机各部件振动耦合会导致转子振动信号表现多尺度特性, 且 SDP 图像包含多传感器同步信息。为获取更全面的特征并提升 CNN 模型的识别准确率, 本文构建了包含残差模块的多感受野卷积神经网络, 采用不同卷积核联合提取调相机振动特征。

### 2.2 MRFCNN 架构

针对传统 CNN 的结构中存在的缺点, 并结合调相机故障信息存在的复杂特征, 本文提出的混合感受野残差卷积神经网络 MRFCNN, 其结构如图 2 所示。

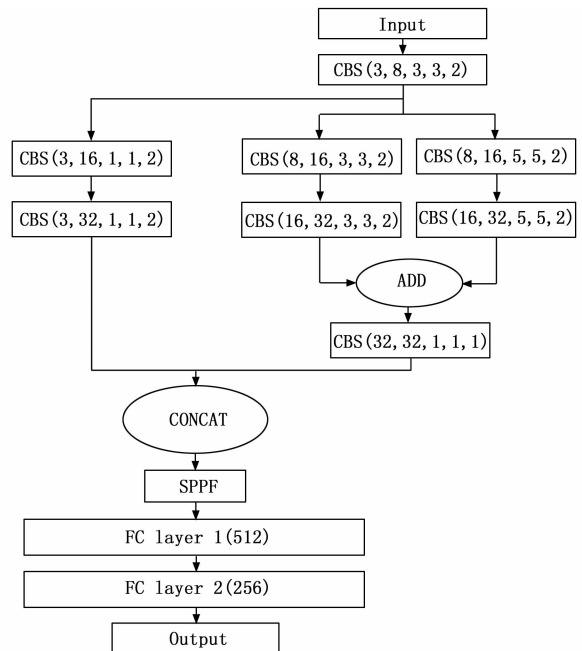


图 2 MRFCNN 网络架构

其中, 本架构中将传统卷积核后添加激活函数的操作改为: 卷积操作 + BN 层 + Silu 激活函数 (简称 CBS 层), 实现在不同卷积特征提取后, 将数据标准化并有效激活权重, CBS 层的结构如图 3 所示。




图 3 CBS 层结构

传统的池化层即下采样层包括平均池 (mean pooling) 和最大池 (max pooling) 等等, 一般直接连接在上一层卷积操作之后, 可以对特征进行压缩、减小计算复杂度。但连续的池化层的堆积, 难免导致丢失信息, 也即降低了图像分辨率, 某些蕴含故障信息的重要特征的丢失将给网络

带来极大损失。因此在 MRFCNN 网络构架中, 用 SPPF 替代传统池化层, 可以从全局角度出发, 有效避免了对图像区域裁剪、缩放操作导致的图像失真等问题, 避免对特征多次重复提取, 提高了分类的精度, 节省计算成本<sup>[22]</sup>, SPPF 的结构原理如图 4 所示。




图 4 SPPF 模块结构

假设输入层为  $128 \times 128$  的原始图像, 在通过第一个  $3 \times 3$  卷积核的 CBS 层后, 数据分流为 3 个支路, 分别为支路 1:  $1 \times 1$  卷积 CBS 支路; 支路 2:  $3 \times 3$  的 CBS 支路; 支路 3:  $5 \times 5$  的 CBS 支路, 因为各支路感受野不同, 可以从多个尺度提取振动特征, 达到特征融合的效果。三条支路均采用两个 CBS 层, 核数量为 16 和 32, 步长均为 2。其中支路 2 与支路 3 的输出进行 ADD 操作, 随后通过  $1 \times 1$  点卷积的 CBS 层, 使数据流平稳, 再与支路 1 的输出进行 CONCAT 操作, 也即与支路 1 形成了残差连接, 降低模型复杂度以防止过拟合, 同时防止梯度消失或梯度爆炸。三条支路 CONCAT 后通过 SPPF 模块进行降维, 使用多个窗口 (pooling window), 提取不同尺寸的空间特征信息, 提升模型对于空间布局和物体变性的鲁棒性。最后为两层全连接层, 并通过 Softmax 实现多分类。

### 3 实验验证

本文提到的 SDP-MRFCNN 模型整体诊断流程如图 5 所示, 实验过程模型按照如下环节进行。

#### 3.1 数据来源

实验数据来自新疆乌鲁木齐天山站 300 MVar 大型同步调相机。该设备两端一端为盘车端, 通过电机带动盘车齿轮进行盘车。另一端为励磁端, 定子接入三相电流生成的旋转磁场以及转子接入直流电形成的稳定磁场共同维持转子转动, 两端均由滑动轴承支撑, 大型调相机实验机组实物及仿真结构示意图如图 6 所示。设备长期运行产生了碰摩, 不平衡的转子故障, 现场振动传感器布置于 1 号: 盘车端  $x$  方向、2 号: 盘车端  $y$  方向、3 号: 励磁端  $x$  方向、4 号: 励磁端  $y$  方向, 通过 SKVMA 振动监测分析仪进行采集, 采样频率为 6 666 Hz。本文所采用故障模式包含正常、碰摩、不平衡 3 种状态。

#### 3.2 SDP 多传感器信息融合

由前文可知, SDP 方法可以通过图像化的方式反映不同信号的特征, 从而体现出调相机不同运行状态间的区别。首先, 设置镜像对称面  $\theta=45^\circ$ , 参数  $\xi=45^\circ$  将调相机 3 种状态的 4 个单一传感器原始信号分别进行 SDP 分解, 各自占

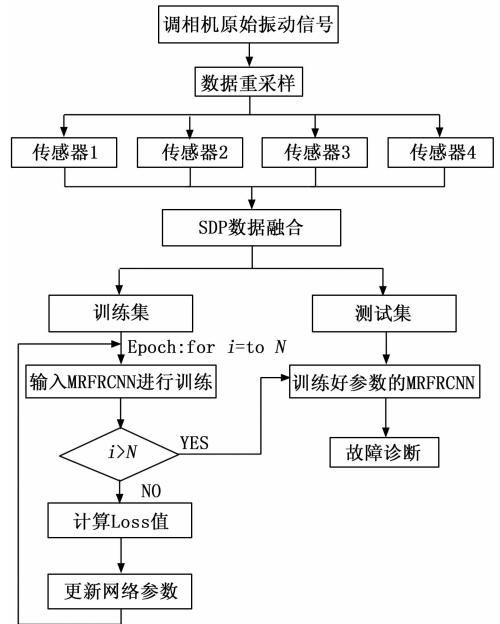




图 5 调相机多传感器信息融合与混合感受野卷积神经网络故障诊断流程图



(a) 300 MVar 大型同步调相机实验机组



(b) 结构仿真示意图

图 6 新疆乌鲁木齐天山站 300 MVar 大型同步调相机

满第一象限, 形成一个清晰且对称的花瓣, 如图 7 所示。

从图 7 可以看出, 直接对单个采集通道进行 SDP 分析, 调相机不同状态间已经可以体现出一定的区别, 但由于 4 个传感器位置不同, 也即包含信息不同, 所以不同传感器采集的信号也是有差异的。因此, 本文通过 SDP 方法将 4 个传感器振动特征进行融合, 设置镜像对称面  $\theta=45^\circ$ 、 $\theta=$

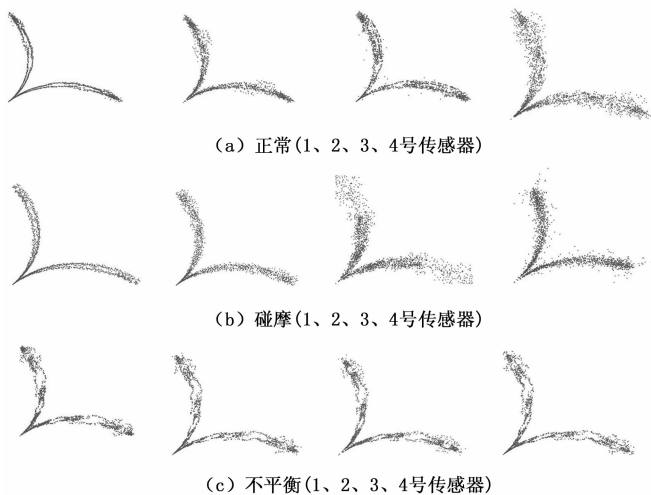


图 7 SDP 图像 (单一传感器信息)

135°、 $\theta=225^\circ$ 、 $\theta=315^\circ$ , 参数  $\theta=45^\circ$ , 也即从第一象限开始旋转, 分别以 1 号、2 号、3 号、4 号传感器信号作为输入, 4 个传感器的信号在极坐标每个象限各形成一对花瓣, 形成最终的四花瓣图。通过将各传感器的振动信息融合起来, 从整体突出状态特征的完整度和区分度, 从而弥补单一特征成分导致的信息缺失。每种运行状态均随机抽取 3 张 SDP 图像作为展示, 如图 8 所示。




图 8 SDP 图像 (融合 1、2、3、4 号传感器信息)

由图 8 可以看出, 单张 SDP 图像将调相机 4 个传感器的时域振动信号在有限范围内充分融合了起来, 在保证不丢失特征的前提下, 极大程度对数据量进行了压缩, 而且更加体现不同出故障特征的可区分度。然而, 通过人为识

别图像特征往往需要大量的预先学习记忆, 并且难以识别图像之间的小差异。另外, 在工业大数据环境下, 极高的采样率导致数据量的暴增, 故人工识别无法满足快速、智能识别的需求。所以本文提出了基于 MRFCNN 的调相机故障 SDP 信息融合图像识别方法, 即通过 SDP-MRFCNN 诊断模型实现调相机转子状态快速识别。

### 3.3 诊断实验

为验证本文方法的有效性, 将经过信息融合的调相机振动 SDP 图像生成数据集, 正常、碰摩、不平衡 3 种状态各 250 条数据, 整体混合后设置随机数打乱数据后, 以 4:1 的比例划分训练集和测试集, 输入网络前 3 种状态被顺序编码为 0、1、2。数据集的构成如表 1 所示。

表 1 数据集构成

状态模式	标签	样本个数 (train/test)
正常	0	250
碰摩	1	250
不平衡	2	250

基于以上数据集, 在 Pytorch 环境下, 搭建多感受野卷积神经网络进行诊断分类。设置网络学习率为 0.000 1, 批样本数为 32, 迭代 50 轮。模型训练后测试集上的结果表明, 测试集最终识别精度达到了 99.33%, 模型在训练集和测试集上的效果曲线如图 9 所示。可以看出, 模型在第 10 个 epoch 左右就达到了较高的精度并开始收敛, 整个训练过程稳定, 没有过拟合、欠拟合的现象出现, 初步说明了本文诊断方法的优秀性。




图 9 模型准确率曲线

为了更加清晰直观地评估模型效果, 将测试集 3 种状态类别分类结果以热图形式绘制混淆矩阵, 如图 10 所示。

图中坐标值 0、1、2 分别为表 1 中的标签编号, 代表调相机的不同状态。阴影中的数字表示为实际样本标签和预测样本标签相符合的概率值, 从混淆矩阵中可以看出测试的总样本中, 除了类别 1 中有 0.01 的概率被误诊为类别 0, 其他预测样本的分类结果均正确。

同时, 引入 T-SNE 方法对测试集数据分类后的全连接




图 10 调相机故障样本分类混淆矩阵

输出层数据进行降维处理，生成聚类簇，使结果进一步可视化，如图 11 所示。综合图 10 和图 11 可以看出，混淆矩阵的分类错误标签与 T-SNE 图中颜色簇的堆叠情况是相对应的。调相机的 3 种运行状态被错误分类的几率非常小，虽然仍可以观察到一定程度的错误诊断，但 T-SNE 聚类结果显示，不同类别间特征边界明显，同类别间特征分布紧凑。总体而言，测试结果表明，本文诊断方法取得了令人十分满意的分类结果。

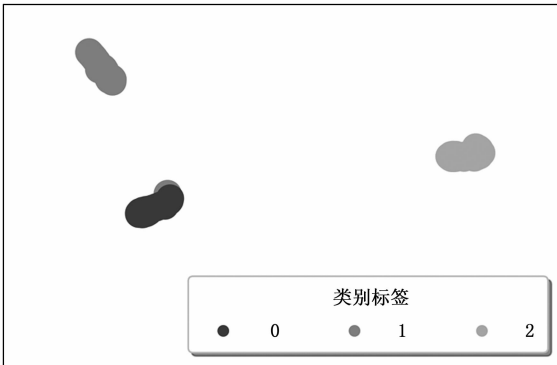


图 11 调相机故障样本分类 T-SNE 图

### 3.4 对比试验

#### 3.4.1 SDP 特征融合优越性

对 1 号传感器的振动数据，分别使用短时傅里叶变换 STFT、小波变换 WT、及非特征融合的 SDP 图 (SoleSDP) 即图 7 所示的未经融合的单—传感器 SDP 图，分别输入本文提出的 MRFCNN 网络结构中进行分类识别，同样以正常、碰摩、不平衡 3 种状态各 250 条数据整体混合后以 4:1 的比例划分训练集和测试集，实验结果如表 2 所示。

表 2 对比实验结果

序号	诊断方法	准确率/%
1	STFT-MRFCNN	93.36
2	WT-MRFCNN	92.02
3	SoleSDP-MRFCNN	94.58
4	SDP-MRFCNN	99.33

实验结果表明，同在本文提出的 MRFCNN 深度学习模型中，STFT 和 WT 时频图作为特征输入时故障分类精度偏低，证明这两种传统时频分析图在调相机故障特征提取过程中对细微特征的提取能力较差；而方法 3 无融合的单—传感器 SDP 图和融合特征的 SDP 图实验结果比对，说明单一 SDP 图虽然较 STFT 和 WT 有更强的细微特征二维化表征能力，但是经多传感器融合后的 SDP 图对分类精度的提升有了更大的提升。

#### 3.4.2 SDP-MRFCNN 与其他模型对比

为了进一步说明所提 SDP-MRFCNN 深度学习网络架构有效性，选取了几种经典旋转机械故障诊断方法在本文数据集上进行测试，进行对比研究：1) EMD-SVM 方法<sup>[23]</sup>，使用 EMD 分解信号，构造 IMF 特征矩阵输入 SVM 进行状态识别；2) DBN 方法<sup>[24]</sup>，通过对多个传感器振动数据提取时域特征并融合，然后输入 DBN 网络，能够自适应融合多传感器数据完成分类任务；3) STFT-CNN 方法<sup>[25]</sup>，利用短时傅里叶变换将信号转化为时频图输入 CNN 进行诊断；4) SDP-CNN 方法<sup>[26]</sup>，将多传感器融合信息的 SDP 图像输入一个传统的 CNN 结构进行诊断分类；5) SDP-VGG<sup>[27]</sup>，将单一传感器信号 (本文采用 3 号传感器) 进行 SDP 分析，得到相应 SDP 图像后，输入 VGG 网络结构中进行分类。6) 本文所提 SDP-MRFCNN 方法，将多传感器融合信息的 SDP 图像输入一个包含多感受野和残差块以及 SPPF 池化的 MRFCNN 模型进行诊断分类。对比实验结果如表 3 所示。

表 3 对比实验结果

序号	诊断方法	准确率/%
1	EMD-SVM <sup>[23]</sup>	82.00
2	DBN <sup>[24]</sup>	87.34
3	STFT-CNN <sup>[25]</sup>	93.34
4	SDP-CNN <sup>[26]</sup>	94.67
5	SDP-VGG <sup>[27]</sup>	90.00
6	SDP-MRFCNN	99.33

由表 2 可知，本文方法识别准确率最高，达到了 99.33%。其他方法的最高准确率仅达到了 94.67%。虽然其他方法也在一定程度上实现了调相机转子故障诊断，但是在原始信号特征过于复杂时，很难以更高精度完成状态特征到识别结果的映射，极易造成误诊。特别地，方法 4 与本文方法十分类似，区别在于 CNN 结构不同，方法 4 采用了传统 CNN，而本文针对传统 CNN 进行了有效改进；方法 5 则没有考虑多传感器信息融合的作用，仅利用单一传感器信息，单一传感器造成的设备状态运行特征不足，与传统诊断模型的特征提取能力弱，均限制了诊断精度的进一步升高。而本文方法 SDP-MRFCNN 在数据处理阶段通过 SDP 图像最小尺度的融合了调相机多传感器的振动信息，同时，MRF-CNN 模型结构避免了传统神经网络的单一感受野以及单支

路卷积、池化的堆叠形式, 具有更强大的特征提取能力, 更利于调相机的故障诊断。

#### 4 结束语

针对受现场强噪声干扰、故障特征复杂的调相机转子振动信号, 本文提出了一种 SDP-MRFCNN 调相机转子故障诊断方法。该方法主要步骤如下: 首先将来自现场设备 4 个不同方位传感器的振动信号通过 SDP 方法进行信息融合, 获取全面、立体的设备运行状态特征; 改进传统分类的 CNN 结构, 构建多尺度、多感受野、具备更强特征学习能力的 MRFCNN 网络; 最后, 基于 MRFCNN 网络对融合信息的 SDP 图像进行识别, 实现调相机转子设备智能故障诊断。通过两组对比实验分别验证了 SDP 多传感器信息融合以及 MRFCNN 网络的优越性, 证明了 SDP-MRFCNN 模型在准确率上具有很大提升, 达到了 99.33%, 大大提高了对于调相机振动信号特征学习效果与状态识别精度。但是, 由于该模型以图形特征作为输入, 对图片数量需求大, 如何针对现场数据不平衡, 克服故障样本量对网络的影响有待于进一步研究; 同时如何在保证分类精度的前提下, 对网络的轻量化研究也是一个改进方向。

#### 参考文献:

- [1] 李志强, 蒋维勇, 王彦滨, 等. 大容量新型调相机关键技术参数及其优化设计 [J]. 大电机技术, 2017 (4): 15-22.
- [2] 尹立敏, 雷 钢, 吕莉莉, 等. 基于同步调相机降低换相失败风险的仿真研究 [J]. 电测与仪表, 2018, 55 (15): 138-143.
- [3] 张玉良, 马宏忠, 蒋梦瑶, 等. 基于 SSI-MSVM 的调相机轴承故障诊断方法 [J]. 电机与控制应用, 2021, 48 (3): 87-93.
- [4] 张开宇, 崔 勇, 庄侃沁, 等. 加装同步调相机对多直流馈入受端电网的影响分析 [J]. 电力系统保护与控制, 2017, 45 (22): 139-143.
- [5] 马明晗, 贺鹏康, 李永刚, 等. 高压直流输电换相失败对带静偏心故障调相机的影响 [J]. 电力自动化设备, 2021, 41 (8): 189-193.
- [6] 马宏忠, 蒋梦瑶, 李呈营, 等. 一种新型同步调相机定子绕组匝间短路故障诊断方法 [J]. 电机与控制学报, 2021, 25 (9): 35-45.
- [7] 蔡艳平, 徐光华, 李艾华, 等. EMD 局部积分均值增密插值改进算法及其在转子故障诊断中的应用 [J]. 振动与冲击, 2016, 35 (19): 81-87.
- [8] 林万德, 王生杰, 包正红, 等. 基于谐波与振动特性的大型调相机转子偏心故障诊断方法 [J]. 河南理工大学学报 (自然科学版), 2021, 40 (6): 132-139.
- [9] 唐贵基, 王晓龙. 可调品质因子小波变换在滚动轴承微弱故障特征提取中的应用 [J]. 中国电机工程学报, 2016, 36 (3): 746-754.
- [10] WAN S T, PENG B. An Integrated Approach Based on Swarm

- Decomposition, Morphology Envelope Dispersion Entropy, and Random Forest for Multi-Fault Recognition of Rolling Bearing [J]. Entropy, 2019, 21 (4): 354.
- [11] 肖幸鑫, 宋礼威, 张翊勋, 等. 基于 CEEMD 与 SVM 的离心泵转子不对中故障诊断方法研究 [J]. 流体机械, 2022, 50 (7): 85-92.
- [12] 雷亚国, 贾 峰, 孔德同, 等. 大数据下机械智能故障诊断的机遇与挑战 [J]. 机械工程学报, 2018, 54 (5): 94-104.
- [13] SCHMIDHUBER J. Deep learning in neural networks: an overview [J]. Neural Networks, 2015, 61: 85-117.
- [15] 彭 威, 李 晶, 刘卫东, 等. AE 声谱图特征的转子碰摩故障识别方法研究 [J]. 振动工程学报, 2019, 32 (6): 1094-1103.
- [16] ZHANG Y, XING K S, Bai R X, et al. An enhanced convolutional neural network for bearing fault diagnosis based on time-frequency image [J]. Measurement, 2020, 157 (99): 107667.
- [17] 李 涛, 段礼祥, 张东宁, 等. 自适应卷积神经网络在旋转机械故障诊断中的应用 [J]. 振动与冲击, 2020, 39 (16): 275-282.
- [18] XU Q S, ZHU B, HUO H B, et al. Fault diagnosis of rolling bearing based on online transfer convolutional neural network [J]. Applied Acoustics, 2022, 192: 108703.
- [19] 朱丹宸, 张永祥, 潘洋洋, 等. 基于多传感器信号和卷积神经网络的滚动轴承故障诊断 [J]. 振动与冲击, 2020, 39 (4): 172-178.
- [20] XU X G, LIU H X, ZHU H, et al. Fan fault diagnosis based on symmetrized dot pattern analysis and image matching [J]. Journal of Sound and Vibration, 2016, 374: 297-311.
- [21] 江泽涛, 秦嘉奇, 张少钦. 参数池化卷积神经网络图像分类方法 [J]. 电子学报, 2020, 48 (9): 1729-1734.
- [22] HE K M, ZHANG X Y, Ren S Q, et al. Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37 (9): 1904-1916.
- [23] LI Y B, MENG F L, LU Y J. Research on rub impact fault diagnosis method of rotating machinery based on EMD and SVM [J]. IEEE, 2009, 2009: 4806-4810.
- [24] TAO J, LIU Y L, YANG D L. Bearing fault diagnosis based on deep belief network and multisensor information fusion [J]. Shock and Vibration, 2016, 2016: 1-9.
- [25] 王春雷, 路小娟. 一种基于深度学习的电机轴承故障诊断方法 [J]. 兰州交通大学学报, 2020, 39 (2): 43-50.
- [26] 朱霄珣, 罗学智, 叶行飞, 等. 基于深度特征学习的汽轮机转子状态识别方法 [J]. 中国电机工程学报, 2021, 41 (2): 432-442.
- [27] 武海彬, 卜明龙, 刘圆圆, 等. 基 SDP 图像 VGG 网络的旋转机械转子故障诊断研究 [J]. 机电工程, 2020, 37 (9): 1069-1074.