

# 控制与决策

Control and Decision

## 基于GADF和PAM-Resnet的旋转机械小样本故障诊断方法

梁浩鹏, 曹洁, 赵小强

引用本文:

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.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.0378>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 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>

#### 基于广义主成分分析的重构故障子空间建模方法

Reconstructed fault subspace modelling method based on generalized principal component analysis

控制与决策. 2021, 36(4): 808–814 <https://doi.org/10.13195/j.kzyjc.2019.0818>

#### 高超声速飞行器间歇故障改进自适应容错控制

Improved adaptive fault-tolerant control of intermittent faults in hypersonic flight vehicle

控制与决策. 2021, 36(11): 2627–2636 <https://doi.org/10.13195/j.kzyjc.2020.0483>

#### 基于核典型相关性-熵成分分析的工业过程质量监测方法

A quality monitoring method for industrial process based on kernel canonical correlation-entropy component analysis

控制与决策. 2021, 36(12): 2999–3006 <https://doi.org/10.13195/j.kzyjc.2020.0548>

#### 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>

# 基于 GADF 和 PAM-Resnet 的旋转机械小样本故障诊断方法

梁浩鹏<sup>1</sup>, 曹洁<sup>1†</sup>, 赵小强<sup>2</sup>

(1. 兰州理工大学 计算机与通信学院, 兰州 730050; 2. 兰州理工大学 电气工程与信息工程学院, 兰州 730050)

**摘要:** 在旋转机械的实际工作中, 由于故障样本有限, 很难实现准确的故障诊断. 对此, 提出一种基于 GADF 和 PAM-Resnet 的小样本故障诊断方法. 首先, 构建一种数据增强策略, 该策略将数目较少的一维信号样本转化为二维 GADF 图, 之后将 GADF 图裁剪成多个子图, 从而得到大量的图像样本, 解决样本数目不足的问题; 然后, 构建一种位置注意力模块 (PAM), 该模块使用横向卷积和纵向卷积分别对横向特征和纵向特征赋予权重, 融合两种特征得到 GADF 图的位置信息; 最后, 将 PAM 插入残差块中构建 PAM 残差块, 并使用多个 PAM 残差块构建 PAM-Resnet, PAM-Resnet 可以有效地关注位置信息, 具有较强的故障特征学习能力. 分别进行小样本环境下的齿轮箱故障诊断和滚动轴承故障诊断实验, 结果表明所提出方法具有较高的故障诊断准确率, 可以准确地诊断出小样本环境下的故障类型.

**关键词:** 旋转机械; 小样本故障诊断; 格拉姆角差域; 位置注意力模块; 残差神经网络; 数据增强

中图分类号: TH133.3; TP206.3

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.0378

引用格式: 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.

## Small sample fault diagnosis method for rotating machinery based on GADF and PAM-Resnet

LIANG Hao-peng<sup>1</sup>, CAO Jie<sup>1†</sup>, ZHAO Xiao-qiang<sup>2</sup>

(1. College of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China; 2. College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China)

**Abstract:** In the actual work of rotating machinery, it is difficult to achieve accurate fault diagnosis because of the limited fault samples. To address this problem, a small-sample fault diagnosis method based on GADF and PAM-Resnet is proposed. Firstly, the proposed method constructs a data enhancement strategy, which converts a small number of 1D signal samples into 2D GADF images, and then crops the GADF images into multiple sub-images to obtain a large number of image samples, which solves the problem of insufficient number of samples. Then, a position attention model (PAM) is constructed, which uses horizontal and vertical convolution to give weights to horizontal features and vertical features, respectively, and fuses the two features to obtain the position information of the GADF image. Finally, the PAM is inserted into the residual block to construct the PAM residual block, and multiple PAM residual blocks are used to construct the PAM-Resnet. The PAM-Resnet can effectively focus on location information and has a strong fault feature learning capability. The fault diagnosis experiments of gearbox and rolling bearing under the small sample environment are carried out respectively, and the results indicate that the proposed method has higher fault diagnosis accuracy and can accurately diagnose the fault types under small sample environment.

**Keywords:** rotating machinery; small sample fault diagnosis; Gramian angular difference field; position attention model; residual neural network; data enhancement

## 0 引言

实际的工程场景中, 旋转机械通常在正常条件下工作, 很少出现故障. 因此, 尽管由多个传感器组成的状态监测系统能够持续地从设备上采集数据, 但采集

的数据大部分是健康数据, 故障数据量较少<sup>[1]</sup>. 在这种情况下, 如果直接使用有限的故障数据训练智能诊断模型, 则会导致模型泛化性能差、故障分类精度低的问题. 总之, 较少的数据量通常难以支持智能诊断

收稿日期: 2022-03-13; 录用日期: 2022-07-06.

基金项目: 国家重点研发计划项目 (2020YFB1713600); 甘肃省重点研发计划项目 (21YF5GA072); 甘肃省教育厅产业支撑计划项目 (2021CYZC-02); 甘肃省教育厅项目 (2022CXZX-476).

†通讯作者. E-mail: haop1115@163.com.

模型的训练,因此,研究出针对少量样本的智能故障诊断方法,对故障诊断领域的发展至关重要.

近年来,随着深度学习方法在机械故障诊断领域的发展,小样本故障诊断的研究取得了不错的成果.根据数据处理策略的不同,基于深度学习的小样本故障诊断方法可分为3大类:基于数据增强的方法,基于数据生成的方法和基于数据特征迁移的方法<sup>[2]</sup>.其中:基于数据增强的方法是指使用一些采样技术实现数据扩充.例如,Zhang等<sup>[3]</sup>用重叠采样技术对样本进行切片,切片后每段信号之间具有重叠部分,从而获得大量的数据样本.但是,此类方法大多使用几何扩充法,扩充后的数据不能有效地模拟原始数据.此外,当样本数目非常少时,此类方法并不能取得较好效果.基于数据生成的方法利用生成对抗网络(generative adversarial network, GAN)生成数据.例如肖雄等<sup>[4]</sup>将电机轴承的一维信号转化为二维灰度图,之后使用GAN实现数据增强.虽然GAN可以生成数据,但是,在网络训练中需要大量的训练样本,当训练样本较少时,生成的数据质低,无法模拟真实数据.基于数据特征迁移的方法大多是指使用迁移学习的策略,例如,曹宁等<sup>[5]</sup>利用迁移成分分析理论构造加权混合核函数,将源域数据与目标域数据映射到同一特征空间进而实现故障诊断.然而,迁移学习的性能与源域和目标域数据的相似性有关,如果两者之间存在较大偏差,则会导致较差的诊断性能.

综上所述,基于深度学习的方法可以使用多种策略扩充样本数目,也取得了不错的成果,但仍存在一些问题.例如:重叠采样方法中样本出现多次重复;GAN的初始训练依赖样本质量和数目;当数据特征差异较大时,迁移学习诊断效果不佳.为了有效诊断小样本条件下的故障,本文提出基于GADF和PAM-Resnet的小样本故障诊断方法.首先,使用GADF变换将时域信号转化为二维GADF图,并通过GADF图裁剪实现数据增强;然后,为了提取GADF图中的特征信息,本文提出一种新型的位置注意力模块,该模块可以帮助深度神经网络关注GADF图中的位置信息;最后,将该模型插入残差块中构建PAM残差块,并通过PAM残差块和全局平均池化层等构建PAM-Resnet网络.PAM-Resnet网络具有较强的特征提取能力,在小样本的条件下可有效实现故障诊断.

## 1 GADF变换理论

近几十年来,研究人员提出了许多一维信号转化为二维图像的方法,尽管这些方法可以有效地将信号

转化为图像并保留原始信号中的故障特征,但是,很大程度上依赖于专家经验和专业知识.针对这些问题,本文通过GADF(gramian angular difference field)变换<sup>[6]</sup>将信号编码成图像,以帮助深度学习方法高精度地识别和诊断故障.假设有 $n$ 个点的时间序列 $X = \{x_1, x_2, \dots, x_n\}$ ,GADF对序列 $X$ 的转化过程可分为以下两个步骤.

step1:首先使用归一化操作将 $X$ 中的值 $x_i$ 缩放到区间 $[-1, 1]$ ,公式如下:

$$\tilde{x}_i = \frac{(x_i - \max(X)) + (x_i - \min(X))}{\max(X) - \min(X)}, \quad (1)$$

其中 $\tilde{x}_i \in \tilde{X}$ .然后,将 $\tilde{X}$ 中的值 $\tilde{x}_i$ 编码为角余弦,时间戳编码为半径,公式如下:

$$\phi_i = \arccos(\tilde{x}_i), \quad (2)$$

$$r = \frac{t_i}{N}. \quad (3)$$

其中: $\phi_i$ 代表角余弦的极坐标, $t_j$ 代表时间戳, $N$ 是调整极坐标系跨度的常数因子.对于值区间在 $[-1, 1]$ 的时间序列,极坐标变换中的反三角函数可以将其控制在区间 $[0, \pi]$ 内.此外,编码系统将时间序列 $\tilde{X}$ 编码的结果是唯一的,并具有唯一的逆映射.

step2:对于存储时间信息的极坐标系统 $\phi$ ,通过计算系统中每个极坐标的三角函数差,可将其编码到矩阵的几何结构中,公式如下:

$$\begin{aligned} \text{GADF} = & \begin{bmatrix} \sin(\phi_1 - \phi_1) & \sin(\phi_1 - \phi_2) & \dots & \sin(\phi_1 - \phi_n) \\ \sin(\phi_2 - \phi_1) & \sin(\phi_2 - \phi_2) & \dots & \sin(\phi_2 - \phi_n) \\ \vdots & \vdots & \ddots & \vdots \\ \sin(\phi_n - \phi_1) & \sin(\phi_n - \phi_2) & \dots & \sin(\phi_n - \phi_n) \end{bmatrix} = \\ & \sqrt{I - \tilde{X}^2}^T \tilde{X} - \tilde{X}^T \sqrt{I - \tilde{X}^2}, \end{aligned} \quad (4)$$

其中 $I = [1, 1, \dots, 1]$ ,它是单位行向量.矩阵的运算形式对应于常规内积的惩罚形式,矩阵的正对角线包含时域信号的原始值和角度信息.之后,将GADF矩阵表示为二维GADF图像,并通过图像建立极坐标以保持绝对时间关系.

## 2 基于GADF和PAM-Resnet的小样本故障诊断方法

### 2.1 GADF数据增强

在小样本条件下的故障诊断过程中,核心在于如何解决样本不足的问题.为此,本文引入GADF变换,并构建一种基于GADF变换的数据增强方法.首先,GADF变换将随时间变化的信号值转化为角度

值,因此,可以通过极坐标保持绝对时域信号的时间关系;然后,通过分析式(4)中GADF矩阵可知,假设包含 $n$ 个点的时间序列 $X$ 经过GADF变换后,将生成 $n \times n$ 的原始GADF图;最后,对原始GADF图进行裁剪并生成多张子图,裁剪前的GADF图尺寸为 $n \times n$ ,通过图像裁剪操作后,子图的大小为 $m \times m$ ,为了保证原始图的完全裁剪, $n$ 需要为 $m$ 的整数倍,即 $n = a \times m (a \in N^*)$ ,因此,裁剪后的一张原始图将生成 $a^2$ 个子图,样本数目明显增多,从而实现了数据增强.需要说明的是,在GADF矩阵中,非对角线上的每个点的值是不同的,因此,裁剪GADF图后得到的子图都是独立的,即每张图都包含着不同的特征信息.在GADF子图中:一部分子图包含了GADF矩阵的正对角线,因此,它们直接代表着信号的时间相关性;另一部分子图虽然不包含GADF矩阵的正对角线,但是它们包含了非相邻信号的三角函数差,这些三角函数差也代表着信号特征,同样可以作为输入样本训练网络,提升网络的故障诊断能力.

## 2.2 位置注意力模块

注意力模块的作用是强化神经网络对目标的学习.例如:SEnet<sup>[7]</sup>注意力关注特征通道不同的权重;EAM<sup>[8]</sup>注意力关注不同时间信号段的权重.但是这些注意力模块都无法关注特征图的位置信息.Resnet<sup>[9]</sup>属于卷积神经网络(CNN)中的一类网络,可有效地预防网络过拟合,它的特征学习能力优于传统CNN.在本文中,一维信号被转化为GADF矩阵,其中一维信号的特征信息被转化为极坐标的三角函数差,通过图像表示时,这些三角函数差分布于GADF图中各个位置,因此,希望Resnet更多地关注每个极坐标的三角函数差,即GADF图的位置信息.基于此目的,本文提出一种新型的位置注意力模块(positional attention module, PAM).PAM首先通过横向卷积和纵向卷积提取特征,其中横向卷积提取特征图的横向特征,纵向卷积提取特征图的纵向特征;然后,分别对横向特征和纵向特征赋予权重;最后,融合两种特征,得到特征图的位置信息.PAM结构如图1所示.

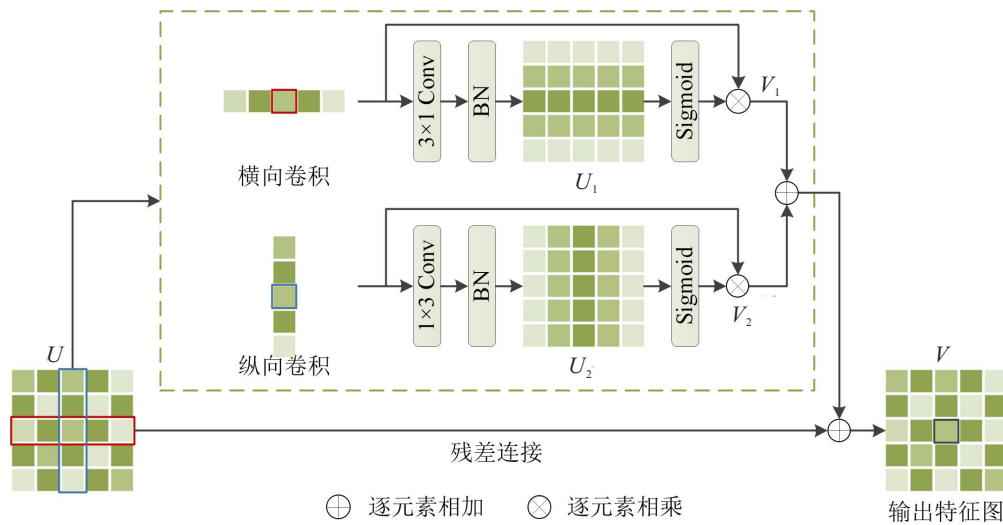


图1 位置注意力模块(PAM)

PAM的处理过程可分为以下3个步骤.

step 1: 输入特征 $U$ 分别经过横向卷积、纵向卷积、BN,得到特征图的横向特征 $U_1$ 和纵向特征 $U_2$ ,每个卷积后而加入BN的作用是为了提高网络的训练效率. $U_1$ 和 $U_2$ 的数学模型可以描述为

$$U_1 = \psi(\delta(U)), \quad (5)$$

$$U_2 = \psi(\theta(U)). \quad (6)$$

其中: $\psi$ 代表BN处理, $\delta$ 代表卷积核为 $3 \times 1$ 的横向卷积, $\theta$ 代表卷积核为 $1 \times 3$ 的纵向卷积.

step 2: 横向特征 $U_1$ 和纵向特征 $U_2$ 分别经过Sigmoid激活函数,其中Sigmoid激活函数的作用是

将特征压缩至 $[0, 1]$ 之间,即得到两个特征的软注意力向量.然后,将两个软注意力向量与输入特征 $U$ 逐元素相乘,得到包含权重的横向特征 $V_1$ 和纵向特征 $V_2$ . $V_1$ 和 $V_2$ 的数学模型可以描述为

$$a = \frac{1}{1 + e^{-U_1}}, \quad (7)$$

$$b = \frac{1}{1 + e^{-U_2}}, \quad (8)$$

$$V_1 = a \cdot U_1, \quad (9)$$

$$V_2 = b \cdot U_2. \quad (10)$$

其中: $a$ 和 $b$ 分别代表 $U_1$ 和 $U_2$ 的软注意力向量, $\cdot$ 代表向量与特征间的逐元素相乘.

step 3: 融合  $V_1$  和  $V_2$ , 融合方式为神经网络中的逐元素相加, 得到位置注意力特征. 此外, 考虑到多次使用注意力模块会降低深层特征的响应值, 本文在 PAM 中添加了残差连接, 帮助特征在网络中传递, 最终生成的特征  $V$  的数学模型可以描述为

$$V = V_1 + V_2 + U. \quad (11)$$

### 2.3 基于位置注意力模块的残差块

为了提高 Resnet 对 GADF 图的位置信息的关注, 需要在残差块中插入 PAM 模块, PAM 残差块结构如图 2 所示.

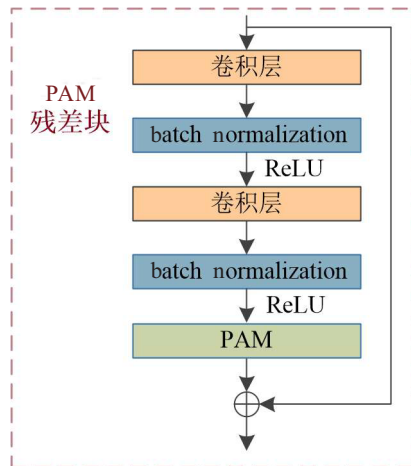


图 2 PAM 残差块结构

在图 2 中, 为了最大程度地发挥 PAM 的效果, 本文把 PAM 插入到残差块的最末层. 原因是考虑到残差块主要通过内部的两个卷积层提取特征, 因此, 调整这两个卷积层的位置注意力至关重要. 此外, 本文参考了注意力网络 SEnet<sup>[7]</sup>, 在 SEnet 中, 注意力模块同样放置于残差块的末端, 因此 PAM 在残差块中的位置是合理的.

### 2.4 基于 GADF 和 PAM-Resnet 方法故障诊断流程

在旋转机械的实际工作中, 很难直接获取足够的故障数据, 这意味着故障诊断方法只能从有限的故障数据中判断故障类型, 特别是基于深度学习的故障诊断方法, 少量样本将导致深度学习模型出现难以训练、诊断效果差等问题. 针对这些问题, 本文提出了基于 GADF 和 PAM-Resnet 的故障诊断方法, 该方法的故障诊断流程可分为两个阶段.

第 1 阶段是数据增强阶段. 在该阶段, 一维时序信号首先通过传感器收集并储存分析, 然后经过 GADF 变换转化为二维 GADF 图. 该过程中 GADF 变换将一维信号重新编码, 并将信号中的信息转化为极坐标的三角函数差, 存储到矩阵的几何结构中, 这种转化方式可以有效地保留一维信号的时序性. 然后将 GADF 图分解为多个大小一致的子图, 从而实现了

数据增强.

第 2 阶段是故障诊断阶段. 在该阶段, 首先构建 PAM-Resnet, PAM-Resnet 使用了多个 PAM 残差块对端相连接构成, 所以 PAM-Resnet 可以关注 GADF 图的位置信息, 即关注每个极坐标的三角函数差, 从而帮助 PAM-Resnet 提取 GADF 图的特征信息, 诊断故障类型. 然后, 将 GADF 图按比例划分为训练数据和测试数据, 并将训练数据输入 PAM-Resnet 中开始训练. 在训练过程中, 采用小批量方式输入训练样本, 计算损失函数, 反向传播更新网络权重参数. 此外, 设置网络迭代的总次数为  $N$ , 当训练次数  $i < N$  时, 返回训练过程, 继续更新网络参数; 当  $i = N$  时, 训练结束, 保存训练模型. 最后, 将测试数据输入训练好的 PAM-Resnet 模型, 输出故障诊断结果.

## 3 实验仿真和结果分析

本节将分别使用齿轮箱数据和滚动轴承数据评估所提出方法的故障诊断能力. 实验的电脑配置为 i9-9900K CPU, NVIDIA RTX2080Ti 处理器和 64 GB 内存. 实验框架为 keras-python.

### 3.1 PAM-Resnet 参数设置

在实验中, 齿轮箱和滚动轴承故障诊断实验使用相同的 PAM-Resnet 参数. 由于深度学习网络的超参数设置至今仍未达成共识, PAM-Resnet 的网络结构和网络参数主要参考了传统 Resnet 和一些著名的网络. 此外, 本着最大化网络性能和最小化训练负担的原则, 通过多次实验, 最终确定 PAM-Resnet 的参数如表 1 所示. 在训练过程中, 使用 Adam 算法更新 PAM-Resnet 的参数. 其中: Adam 算法的初始学习率为 0.001, 衰减率为 0.9, 训练样本以小批量样本训练, 每批样本数为 32, 迭代次数为 50.

表 1 PAM-Resnet 参数设置

结构	核尺寸	步长	通道数	输出尺寸
卷积层	3×3	1	16	64×64
最大池化层	2×2	2	16	32×32
PAM 残差块	3×3	2	32	16×16
	3×3	1	32	16×16
PAM 残差块	3×3	2	64	8×8
	3×3	1	64	8×8
PAM 残差块	3×3	2	64	4×4
	3×3	1	64	4×4
PAM 残差块	3×3	2	128	2×2
	3×3	1	128	2×2
GAP			128	
Softmax				5 或 10

### 3.2 案例 1

#### 3.2.1 数据描述

行星齿轮箱数据集通过东南大学 Spectra Quest 齿轮传动系统收集,系统的转速负载条件分别为转速 20 Hz (1 200 rpm)、无负载 0 V (0 N·m). 齿轮箱数据故障类型共有 5 种,分别是齿轮断齿、齿轮缺口、齿根裂纹、齿面磨损和健康. 因此,案例 1 的任务是准确诊断出 5 种齿轮箱故障. 在本案例中,设置两种小样本环境,采样点设置为 1 024,经过滑动采样后,每一类数据随机截取 10 个和 30 个样本. 然后,对这些样本使用 GADF 变换,每个样本生成一张 1 024×1 024 大小的图,共生成 10 张和 30 张图. 最后,对这些图片进行裁剪,为了满足神经网络的输入需求,设置子图的大小为 64×64,因 1 024 = 16×64,故每张 1 024×1 024 大小的图可裁剪为 256 张 64×64 大小的图,这意味着在小样本故障诊断中,原始的 10 个和 30 个一维样本经过数据增强操作后,最终分别生成 2 560 张和 7 680 张二维图. 之后,将这些图按照 5 : 1 的比例分为训练样本和测试样本.

#### 3.2.2 结果分析

##### 1) 齿轮箱故障实验分析.

在该案例中,为了验证 GADF 数据增强和 PAM 模块的重要性,本文构建两种对比方法 Resnet-1 和 Resnet-2. 其中: Resnet-1 是指一维信号经过 GADF 变换后,只使用包含了 GADF 矩阵的正对角线的图作为训练样本, Resnet-1 的网络结构只使用两个 PAM 残差块,其余参数与所提出方法相同; Resnet-2 未使用 PAM 模块,其余参数与本文所提出方法相同. PAM-Resnet 代表本文所提出方法. 实验结果如表 2 所示.

表 2 中的样本数目代表原始样本的总数目,分别是 50 个和 150 个样本.

表 2 齿轮箱故障诊断准确率 %

不同方法	50 个样本	150 个样本
Resnet-1	59.37	68.12
Resnet-2	97.16	98.20
PAM-Resnet	99.29	99.66

在表 2 中,两种小样本环境下, Resnet-1 的诊断准确率明显低于 Resnet-2 和 PAM-Resnet. 分析其原因, Resnet-1 只使用了 GADF 变换的正对角线图作为训练样本,所以它的样本数目远低于 Resnet-2 和 PAM-Resnet,这表明在 GADF 矩阵中,非对角线上的元素包含了信号的重要特征信息,同时也表明了在小样本故障诊断中,使用非对角线子图的必要性. 在两种小样本环境下, Resnet-2 的准确率为 97.16 % 和 98.20 %, PAM-Resnet 的准确率为 99.29 % 和 99.66 %,由此可见 Resnet-2 的效果并不如 PAM-Resnet,原因是 PAM-Resnet 使用了位置注意力模块 (PAM). 由于一维信号被转化为 GADF 矩阵时,极坐标的三角函数差值分布于 GADF 图的各个位置,而 PAM 能帮助 Resnet 关注 GADF 图的位置信息,因此 PAM-Resnet 能够关注到极坐标信息,并学习到更多的故障信息,为准确分类故障提供了保障.

为了更清楚地分析 3 种方法的故障诊断效果,本文引入混淆矩阵来显示 50 个样本下的故障诊断结果,如图 3 所示. 其中:横纵坐标的标签 0~4 代表 5 种故障类型,横坐标代表预测标签,纵坐标代表实际标签.




图 3 3 种方法的混淆矩阵结果

由图 3 可以看出 Resnet-1 的效果最差,大量的样本被错误分类. 由此可知,只使用对角线图作训练样本,效果无法令人满意. Resnet-2 存在 4 类故障的错误分类,而 PAM-Resnet 只存在一类故障的错误分类,这

表明位置注意力模块 (PAM) 对 PAM-Resnet 的故障诊断性能有很大帮助,在小样本的环境下, PAM-Resnet 几乎能准确地分类所有的故障样本.

为了更直观、更全面地评价所提出方法在小样

本条件下的故障诊断性能,本文引入了精确率、召回率和  $F_1$  值评价指标.表3为50个样本下齿轮箱故障诊断多指标结果,其中多指标包括精确率、召回率和  $F_1$  值3种指标.可以看出:Resnet-1的故障诊断结果是最差的;Resnet-2尽管取得了良好的故障诊断结果,但是整体性能依然低于PAM-Resnet.综上,通过3种评价指标,PAM-Resnet表现出更好的小样本齿轮箱故障诊断结果.

表3 50个样本下齿轮箱故障诊断多指标结果 %

不同方法	精确率	召回率	$F_1$ 值
Resnet-1	69.27	58.84	56.51
Resnet-2	97.21	97.15	97.16
PAM-Resnet	99.31	99.28	99.30

### 2) 齿轮箱故障不同测试样本数目实验分析.

考虑到训练样本和测试样本的数目比例对故障诊断方法的性能具有一定的影响,在本案例中进行了不同测试样本数目实验.具体而言,该部分改变了训练样本与测试样本的数目比例,并将训练样本和测试样本的数目比例设置为2:1.两种小样本环境下的齿轮箱故障诊断实验结果如表4所示.

表4 不同测试样本数目齿轮箱故障诊断准确率 %

不同方法	50个样本	150个样本
Resnet-1	50.24	61.67
Resnet-2	95.21	97.15
PAM-Resnet	99.10	99.57

从表4中可以看出,随着测试样本的数目的增加,每种方法的准确率均有所下降.然而,PAM-Resnet由于使用了GADF数据增强策略,在两种小样本环境下的准确率均达到了99%以上,这表明所提出PAM-Resnet具有较强的鲁棒性,当训练样本和测试样本数目变动较大时,依然可以有效诊断出小样本条件下的故障类型.

### 3) 齿轮箱故障数据不平衡实验分析.

在实际的旋转机械工作环境中,故障发生的次数是较少的,从而使得传感器收集的振动信号多数是健康信号,因此,健康信号与故障信号间的数据不平衡以及不同类别故障信号间的数据不平衡是故障诊断中常见的情况.为了验证所提出方法在不平衡数据条件下的故障诊断性能,案例1构建了齿轮箱数据不平衡实验环境,该环境中,健康数据类别样本数目为30个,齿轮断齿故障类别样本数目为20个,齿轮缺口故障类别样本数目为15个,齿根裂纹故障类别样本数目为10个,齿面磨损样本数目故障类别为5个,实

验结果如表5所示.

表5 齿轮箱故障数据不平衡故障诊断结果 %

不同方法	准确率	精确率	召回率	$F_1$ 值
Resnet-1	65.23	53.17	52.33	49.57
Resnet-2	95.43	94.40	95.21	94.60
PAM-Resnet	99.15	98.93	99.05	98.99

在表5中,Resnet-1方法各项指标的结果是最差的,这验证了本文所提出GADF数据增强策略的必要性.通过对比Resnet-2和PAM-Resnet的各项指标可以看出,PAM-Resnet的实验结果明显高于Resnet-2,这表明本文所提出PAM位置注意力机制可以有效改进网络模型特征学习的效率.此外,PAM-Resnet的准确率指标和召回率指标均在99%以上,这表明它可以有效地诊断出不平衡数据环境下齿轮箱故障.

## 3.3 案例2

### 3.3.1 数据描述

实验数据由美国凯斯西储大学(CWRU)轴承数据中心提供,轴承类型为SKF6205,轴承故障通过人为制造.故障位置有3个,分别在球、内圈、外圈6点钟方向上.故障直径有3种,分别是0.007 in、0.014 in和0.021 in.轴承故障数据通过加速度传感器采集,采集频率为12 kHz,轴承转速为1730 r/min.轴承的每个故障位置和每种故障直径对应于一类故障,因此,故障数据有9种,健康数据有1种,轴承数据总共包括10个标签,案例2的任务是准确分类出10种轴承故障.实验环境等同于案例1,采样点数为1024,每一类数据随机截取10个和30个样本,原始样本经过GADF变换和图片裁剪后,最终分别生成2560张和7680张二维图,并将按照5:1的比例分为训练样本和测试样本.

### 3.3.2 结果分析

#### 1) 滚动轴承故障实验分析.

在该案例中,使用与案例1相同的对比方法Resnet-1和Resnet-2.小样本实验环境分为100和300个样本.实验结果如表6所示.

表6 滚动轴承故障诊断准确率 %

不同方法	100个样本	300个样本
Resnet-1	73.75	89.37
Resnet-2	98.36	98.15
PAM-Resnet	99.78	99.35

从表6中可以看出,Resnet-1在100个样本环境下的准确率为73.75%,300个样本环境下的准确率为89.37%,可见,样本数目的增多有利于提高深度

学习方法的诊断性能。但是,由于Resnet-1仅仅使用GADF矩阵正对角线样本,性能受到限制,无法满足实际诊断需求。两种小样本环境下,Resnet-2的诊断准确率均低于PAM-Resnet,这表明在PAM的作用下,PAM-Resnet能够更有效地学习GADF图中的故障特征,更精准地关注位置信息,因此,该方法具有更高的故障诊断准确率。

2) 所提出方法与先进算法性能对比。

为了进一步验证本文方法的优越性,选取7种先进的小样本滚动轴承故障诊断方法作为对比方法。其中:BNCNN<sup>[10]</sup>是一种结合监督数据增强策略和批量归一化卷积神经网络的方法,1DCNN<sup>[11]</sup>是一种基于紧凑型自适应一维卷积神经网络的方法,迁移学习<sup>[12]</sup>是一种基于改进迁移学习策略的方法,改进GAN<sup>[13]</sup>是一种结合连续小波变换和半监督生成对抗网络的方法,GPGAN<sup>[14]</sup>是一种基于多模态梯度惩罚生成对抗网络的方法,DRHRML<sup>[15]</sup>是一种结合数据重构和元学习策略的方法,FSWT-EAPN<sup>[16]</sup>是一种结合频率切片小波变换、空洞卷积和注意力机制模块的方法,对比结果如表7所示。

表7 不同滚动轴承故障诊断方法对比 %

不同方法	准确率
BNCNN	98.79
1DCNN	93.22
迁移学习	93.23
改进GAN	98.00
GPGAN	99.20
DRHRML	97.83
FSWT-EAPN	99.26
所提出方法	99.35

从表7中可以看出,本文选取了300个小样本条件下的故障诊断结果,所提出方法的准确率为99.35%,明显高于7种对比方法。实验结果表明了本文方法的优越性。

## 4 结论

为了解决小样本环境下齿轮箱和滚动轴承故障诊断方法效果差的问题,本文提出了一种基于GADF和PAM-Resnet的故障诊断方法,并得到了以下结论:

1) 本文通过GADF变换解决了样本数目不足的问题,一维信号经过GADF变换转化为GADF图像,之后通过裁剪,得到了大量的图像样本。然后,设计了位置注意力模块(PAM),该模型可以提升Resnet对GADF位置信息的关注。因此,Resnet可以有效地学

习故障特征信息,准确地识别故障类型。

2) 本文分别使用齿轮箱数据和滚动轴承数据验证了所提出方法的有效性,在两种小样本环境下,所提出方法都能准确地分类出两种数据的故障类型。此外,通过与其他方法的对比,验证了非对角线GADF图的重要性,它们作为训练样本能给本文方法带来很大程度的效果提升,并且验证了PAM能帮助所提出方法更准确地诊断故障,以及本文方法在小样本故障诊断中的优越性。

3) 虽然本文方法可以有效地诊断小样本环境下的故障,但是,一维数据经过数据增强后,样本数目变多的同时也会加重网络的训练负担,因此,未来将针对轻量化网络模型做进一步的研究。

## 参考文献(References)

- [1] 黄南天, 杨学航, 蔡国伟, 等. 采用非平衡小样本数据的风机主轴轴承故障深度对抗诊断[J]. 中国电机工程学报, 2020, 40(2): 563-574.  
(Huang N T, Yang X H, Cai G W, et al. A deep adversarial diagnosis method for wind turbine main bearing fault with imbalanced small sample scenarios[J]. Proceedings of the CSEE, 2020, 40(2): 563-574.)
- [2] Zhang T C, Chen J L, Li F D, et al. Intelligent fault diagnosis of machines with small & imbalanced data: A state-of-the-art review and possible extensions[J]. ISA Transactions, 2022, 119: 152-171.
- [3] Zhang W, Peng G, Li C, et al. A new deep learning model for fault diagnosis with good anti-noise and domain adaptation ability on raw vibration signals[J]. Sensors: Basel, Switzerland, 2017, 17(2): E425.
- [4] 肖雄, 肖宇雄, 张勇军, 等. 基于二维灰度图的数据增强方法在电机轴承故障诊断的应用研究[J]. 中国电机工程学报, 2021, 41(2): 738-749.  
(Xiao X, Xiao Y X, Zhang Y J, et al. Research on the application of the data augmentation method based on 2D gray pixel images in the fault diagnosis of motor bearing[J]. Proceedings of the CSEE, 2021, 41(2): 738-749.)
- [5] 曹宁, 江志农, 高金吉. 小样本下基于迁移学习的轴承状态识别方法[J]. 噪声与振动控制, 2020, 40(5): 89-94.  
(Cao N, Jiang Z N, Gao J J. Rolling bearing state recognition based on transfer learning under small samples[J]. Noise and Vibration Control, 2020, 40(5): 89-94.)
- [6] Sun S Y, Ren J. GASF-MSNN: A new fault diagnosis model for spatiotemporal information extraction[J]. Industrial & Engineering Chemistry Research, 2021, 60(17): 6235-6248.
- [7] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, 2018:

- 7132-7141.
- [8] Wang H, Liu Z L, Peng D D, et al. Understanding and learning discriminant features based on multiattention 1DCNN for wheelset bearing fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2020, 16(9): 5735-5745.
- [9] He K M, Zhang X Y, Ren S Q, et al. Identity mappings in deep residual networks[C]. European Conference on Computer Vision. Cham: Springer International Publishing, 2016: 630-645.
- [10] Lv H X, Chen J L, Zhang T C, et al. SDA: Regularization with cut-flip and mix-normal for machinery fault diagnosis under small dataset[J]. ISA Transactions, 2021, 111: 337-349.
- [11] Eren L, Ince T, Kiranyaz S. A generic intelligent bearing fault diagnosis system using compact adaptive 1D CNN classifier[J]. Journal of Signal Processing Systems, 2019, 91(2): 179-189.
- [12] 张西宁, 余迪, 刘书语. 基于迁移学习的小样本轴承故障诊断方法研究[J]. 西安交通大学学报, 2021, 55(10): 30-37.  
(Zhang X N, Yu D, Liu S Y. Fault diagnosis method for small sample bearing based on transfer learning[J]. Journal of Xi'an Jiaotong University, 2021, 55(10): 30-37.)
- [13] 徐林, 郑晓彤, 付博, 等. 基于改进GAN算法的电机轴承故障诊断方法[J]. 东北大学学报: 自然科学版, 2019, 40(12): 1679-1684.  
(Xu L, Zheng X T, Fu B, et al. Fault diagnosis method of motor bearing based on improved GAN algorithm[J]. Journal of Northeastern University: Natural Science, 2019, 40(12): 1679-1684.)
- [14] Zhang T C, Chen J L, Li F D, et al. A small sample focused intelligent fault diagnosis scheme of machines via multimodules learning with gradient penalized generative adversarial networks[J]. IEEE Transactions on Industrial Electronics, 2021, 68(10): 10130-10141.
- [15] Su H, Xiang L, Hu A J, et al. A novel method based on meta-learning for bearing fault diagnosis with small sample learning under different working conditions[J]. Mechanical Systems and Signal Processing, 2022, 169: 108765.
- [16] Wang C D, Sun H C, Cao X. Construction of the efficient attention prototypical net based on the time-frequency characterization of vibration signals under noisy small sample[J]. Measurement, 2021, 179: 109412.

### 作者简介

梁浩鹏(1995—), 男, 博士生, 从事故障诊断、深度学习等研究, E-mail: 928782706@qq.com;

曹洁(1966—), 女, 教授, 博士生导师, 从事智能交通、计算机控制技术和智能信息处理等研究, E-mail: haop1115@163.com;

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

## 下 期 要 目

- 时空视角下的动态多目标进化算法研究综述 ..... 范勤勤, 等
- 多切入机制下基于信息物理系统的混合车群协同控制 ..... 黄 帅, 等
- 智能车辆路径跟踪控制方法 ..... 李学鋈, 等
- 基于深度强化学习求解作业车间机器与AGV联合调度问题 ..... 孙爱红, 等
- 一种基于超粒子引导的自适应知识迁移多任务差分进化算法 ..... 孙 倩, 等
- 基于模糊函数多域特征融合与集成学习的雷达辐射源信号识别 ..... 普运伟, 等
- 城市生活垃圾焚烧过程二次风量智能优化设定方法 ..... 丁晨曦, 等
- 基于水波进化和动态莱维飞行的爬行动物搜索算法 ..... 付 华, 等
- 融合多策略的改进秃鹰搜索算法 ..... 郭云川, 等
- 基于决策变量关系的动态多目标优化算法 ..... 呼子宇, 等
- 基于多级表征线索注意模型的轻量化抠图方法 ..... 刘相良, 等
- 面向大型工程多安全指标的解析可追溯安全控制方法 ..... 宋鑫涛, 等
- 基于视觉语义与激光点云交融构建的SLAM算法 ..... 佟国峰, 等