



DOI:10.12404/j.issn.1671-1815.2403591

引用格式:郑心成,郝如江,姚勃羽,等.优化辛几何模态分解及改进 ResNeXt 神经网络的齿轮箱故障诊断方法[J].科学技术与工程,2025,25(7):2792-2799.

Zheng Xincheng, Hao Rujiang, Yao Boyu, et al. Gearbox fault diagnosis method based on optimized SGMD and improved ResNeXt neural network[J]. Science Technology and Engineering, 2025, 25(7): 2792-2799.

机械、仪表工业

# 优化辛几何模态分解及改进 ResNeXt 神经网络的齿轮箱故障诊断方法

郑心成, 郝如江\*, 姚勃羽, 王天池, 尚腾龙, 冯鹏帆

(石家庄铁道大学机械工程学院, 石家庄 050043)

**摘要** 故障诊断领域中常将信号处理与深度学习相结合以实现更好的诊断效果。基于此,对辛几何模态分解与 ResNeXt 神经网络分别进行了改进与优化,提出了一种基于优化辛几何模态分解与改进 ResNeXt 神经网络相结合的齿轮箱故障诊断模型。首先将采集到的振动信号经优化辛几何模态分解进行筛选重构,得到有效分量,之后送入改进 ResNeXt 神经网络进行故障的识别分类。通过使用渥太华大学滚动轴承变工况数据,验证了模型的可行性;通过使用动力传动故障诊断综合实验台(drivetrain dynamics simula, DDS)齿轮箱数据进行对比实验与抗噪性实验,验证了改动的有效性与模型的泛化性。

**关键词** 辛几何模态分解; 信号处理; ResNeXt; 故障诊断

中图分类号 TH132; 文献标志码 A

## Gearbox Fault Diagnosis Method Based on Optimized SGMD and Improved ResNeXt Neural Network

ZHENG Xin-cheng, HAO Ru-jiang\*, YAO Bo-yu, WANG Tian-chi,  
SHANG Teng-long, FENG Peng-fan

(School of Mechanical Engineering, Shijiazhuang Tiedao University, Shijiazhuang 050043, China)

**[Abstract]** Signal processing and deep learning are often combined to achieve better diagnostic results in the field of fault diagnosis. Based on this, the symplectic geometric mode decomposition was improved and the ResNeXt neural network was optimized, and then a gearbox fault diagnosis model was proposed based on the combination of optimized symplectic geometric mode decomposition and ResNeXt neural network was improved. Firstly, the collected vibration signals were filtered and reconstructed by optimized symplectic geometric mode decomposition to obtain the effective components. Then it was sent to the improved ResNeXt neural network for fault recognition and classification. The rolling bearing variable condition data from the University of Ottawa was used to verify the feasibility of the model. The gearbox data from drivetrain dynamics simula (DDS) was used for contrast experiment and anti-noise experiment, which verified the effectiveness of changes and the generalization of the model.

**[Keywords]** symplectic geometry mode decomposition; signal processing; ResNeXt; fault diagnosis

作为重要的基础性部件之一,齿轮箱在各类机械设备中得到广泛应用<sup>[1]</sup>。齿轮箱在故障状态下产生的振动信号与正常状态存在差异,且故障类型不同,信号特征也各不相同,这使得对齿轮箱振动信号进行采集、处理、分析、进而对其运行状况做出判断成为可能。

故障诊断方法主要分为3类:基于模型的方法、基于知识规则的方法和基于数据驱动的方法<sup>[2]</sup>。基于数据驱动的方法又可细分为信号处理的方法,如经验模态分解(empirical mode decomposition, EMD)、变分模态分解(variational mode decomposition, VMD)等;以及人工智能方法,如卷积神经网络

收稿日期:2024-05-15 修订日期:2024-08-01

基金项目:国家自然科学基金(12272243);河北省科技研发平台建设专项(21567622H);石家庄铁道大学创新项目(YC202430)

第一作者:郑心成(1997—),男,汉族,河北石家庄人,硕士研究生。研究方向:机电系统故障诊断。E-mail:1300180322@qq.com。

\*通信作者:郝如江(1972—),男,汉族,河北沧州人,博士,教授。研究方向:机电系统故障诊断。E-mail:13931131098@139.com。

投稿网址:www.stae.com.cn

(convolution neural network, CNN)。这两种方法常常结合使用,在提升识别准确率的同时完善现有的故障诊断模型框架<sup>[3]</sup>。张立智等<sup>[4]</sup>针对旋转机械振动信号复杂,故障特征提取困难,提出了一种 EMD、奇异值分解和 CNN 相结合的故障诊断方法。崔桂艳等<sup>[5]</sup>提出一种基于 VMD 灰度图像编码与 CNN 相结合的多传感融合轴承故障诊断方法,解决了滚动轴承振动信号非平稳、非线性且易受噪声干扰的问题。谷娜等<sup>[6]</sup>提出一种变分模态分解、粒子群优化算法和卷积神经网络相结合的齿轮故障诊断方法,克服了齿轮工况复杂多变的难题,且具有较高的识别准确率。

在原有信号处理方法的基础上,潘海洋<sup>[7]</sup>提出了辛几何模态分解(symplectic geometry mode decomposition, SGMD),并将其应用到行星齿轮箱的故障诊断分析中,取得了良好效果。该方法能够保留信号的时间特征,具备良好的信号分解能力与噪声鲁棒性,但也存在着诸如相似分量重组问题和需要人为设置迭代终止条件等问题<sup>[8]</sup>。基于此,现提出优化 SGMD,该方法在原有 SGMD 的基础上加入层次聚类<sup>[9]</sup>与分量间信噪比比较,解决了传统 SGMD 存在的上述问题。在此基础上,进一步提出优化 SGMD 与改进 ResNeXt 神经网络相结合的齿轮箱故障诊断模型,振动信号经优化 SGMD 筛选得到信号的有效分量,之后将其送入改进的 ResNeXt 神经网络完成故障分类。

## 1 相关理论

### 1.1 优化辛几何模态分解

#### 1.1.1 辛几何模态分解

设振动信号的时间序列为  $x = \{x_1, x_2, \dots, x_n\}$ , 其中  $n$  为信号的时间序列长度。依据 Takens 嵌入定理,对  $x$  进行相空间重构得到轨迹矩阵  $X$ ,即

$$X = \begin{bmatrix} x_1 & x_{1+\gamma} & \cdots & x_{1+(t-1)\gamma} \\ x_2 & x_{2+\gamma} & \cdots & x_{2+(t-1)\gamma} \\ \vdots & \vdots & \cdots & \vdots \\ x_m & x_{m+\gamma} & \cdots & x_{m+(t-1)\gamma} \end{bmatrix} \quad (1)$$

式(1)中: $\gamma$  为延时时间; $t$  为嵌入维度; $m = n - (t-1)\gamma$ 。

对  $X$  进行自相关分析得到协方差矩阵  $A = X^T X$ ,进而构造得到哈密顿矩阵(Hamiltonian matrix)  $M$ ,即

$$M = \begin{bmatrix} A^T & 0 \\ 0 & -A^T \end{bmatrix} \quad (2)$$

令  $W = M^2$ ,可得辛正交矩阵  $Q$  存在

$$Q^T W Q = \begin{bmatrix} S & R \\ 0 & S^T \end{bmatrix} \quad (3)$$

式(3)中: $R$  为矩阵中除去  $S, S^T$  和 0 后剩余部分; $S$  为上三角矩阵,经计算得矩阵  $S$  的特征值为  $\lambda_1, \lambda_2, \dots, \lambda_t$ 。

由于  $Q$  具备辛矩阵的特性,故哈密顿矩阵的结构并不会因矩阵变换而发生改变。根据哈密顿矩阵的性质可知,矩阵  $A$  的特征值  $\sigma_i$  与矩阵  $S$  的特征值间存在着关系  $\sigma_i = \sqrt{\lambda_i}$  ( $i = 1, 2, \dots, t$ ),与  $\sigma_i$  对应的特征向量为  $Q_i$  ( $i = 1, 2, \dots, t$ )。将特征值  $\sigma_i$  与特征向量  $Q_i$  降序排列,通过  $Q_i$  与轨迹矩阵  $X$  构造变换系数  $S_i = Q_i^T X^T$  ( $i = 1, 2, \dots, t$ ),从而得到重构轨迹矩阵  $Z = Z_1 + Z_2 + \dots + Z_t$ ,其中分量矩阵  $Z_i = Q_i S_i$  ( $i = 1, 2, \dots, t$ )。

对分量矩阵对角平均处理,将其转化为长度为  $n$  的时间序列。定义分量矩阵  $Z_i$  各个元素为  $z_{ij}$  ( $1 \leq i \leq t, 1 \leq j \leq m$ ),令  $t^* = \min(m, t), m^* = \max(m, t)$ ,以及存在  $n = m + (t-1)\gamma$ ,对角平均转化的公式为

$$y_k = \begin{cases} \frac{1}{k} \sum_{p=1}^k z_{p, k-p+1}^*, & 1 \leq k < t^* \\ \frac{1}{t^*} \sum_{p=1}^{t^*} z_{p, k-p+1}^*, & t^* \leq k < m^* \\ \frac{1}{n-k+1} \sum_{p=k-m^*+1}^{n-m^*+1} z_{p, k-p+1}^*, & m^* \leq k < n \end{cases} \quad (4)$$

式(4)中:若  $m < t$ ,则  $z_{ij}^* = z_{ij}$ ,若  $m \geq t$ ,则  $z_{ij}^* = z_{ji}$ 。

由式(4)逐一计算,可得到一组长度为  $n$  的时间序列  $Y_i = (y_1, y_2, \dots, y_n)$ ,按照以上步骤对分量矩阵依次计算,最终会得到  $t$  组时间序列,将其排列构建为矩阵  $Y$ ,可得到初始辛几何分量  $Y = Y_1 + Y_2 + \dots + Y_t$ 。

#### 1.1.2 优化辛几何模态分解

在原有 SGMD 方法的基础上,本文引入层次聚类与信噪比理论对得到的初始辛几何分量进一步处理。

通过对初始辛几何分量采用层次聚类的方法进行合并重组,能够将相似度较高的分量进行组合,更好地凸显不同分量组合之间的差异<sup>[10]</sup>。将每个初始辛几何分量  $Y_i$  看作一个聚类中心  $s_i = (Y_i)$ ,从而构成  $Y$  的聚类集合  $S = (s_1, s_2, \dots, s_t)$ 。使用斯皮尔曼相关系数  $\rho$  依次计算每两个聚类中心间的相关性,公式为

$$\rho = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)} \quad (5)$$

式(5)中:  $\rho$  为斯皮尔曼系数;  $d_i$  为变量在两个聚类中心间的秩次差。斯皮尔曼系数越大, 两个聚类的相似程度越高。

将相似程度最高的两个聚类 ( $s_m, s_n$ ) 合并为  $s_h$ , 同时合并其对应的辛几何分量。合并后新的聚类集合为  $S = (s_1, s_2, \dots, s_{l-1})$ , 辛几何分量矩阵为  $Y = Y_1 + Y_2 + \dots + Y_{l-1}$ 。重复上述操作, 直至聚类个数降至  $p$  时停止合并。重组后的聚类辛几何分量为

$$Y = Y_1 + Y_2 + \dots + Y_p \quad (6)$$

振动信号成分复杂, 需对其进行筛选处理后再进行后续操作。本文中通过使用信噪比理论, 对聚类辛几何分量进行划分, 从中提取出相关性较强的分量。设振动信号的时间序列为  $x = \{x_1, x_2, \dots, x_n\}$ , 其与前  $m$  个辛几何组合分量间的信噪比被定义为

$$SNR_m = 10 \lg \frac{\sum_{i=1}^n x_i^2}{\sum_{i=1}^n (x_i - \sum_{t=1}^m Y_i^m)^2} \quad (7)$$

当  $SNR_m - SNR_{m+1} > 0$  时, 此时  $m$  点为信号分离点, 此时的分量  $Y = \sum_{i=1}^m Y_i$  为有效辛几何组合分量。

## 1.2 改进 ResNeXt 神经网络

### 1.2.1 ResNeXt 神经网络

该网络由 Xie 等<sup>[11]</sup> 于 2017 年提出。其结合了 Inception 模块的多分支结构的分割-变换-聚合思想与残差网络 (ResNet) 的层间残差跳连思想。该网络由重复的多个网络单元构成。每个单元中通过将不同的卷积层通过并联的方式相结合, 在同层网络中使用不同尺寸的卷积核提取上层特征, 并在最后进行拼接, 提升了模型的感知力; 同时使用了层间残差跳连, 引入前方信息, 缓解了梯度消失。ResNeXt 网络单元可以被具体定义为

$$y = x + \sum_{i=1}^G T_i(x) \quad (8)$$

式(8)中:  $x$  为输入数据,  $y$  为输出数据;  $T_i$  为并行支路, 其具有相同的拓扑结构, 分别进行同种卷积操作;  $G$  为支路个数, 文中  $G = 32$ 。

由于使用了残差结构, ResNeXt 网络单元处于不同位置时, 其输出维度会存在差异。当维度相同时可使用捷径 (shortcut) 直接相加, 当维度不同时需对其使用  $1 \times 1$  的卷积进行调整, 故 ResNeXt 网络单元存在两种结构: 即恒等映射单元如图 1 所示, 以及投影映射单元如图 2 所示。

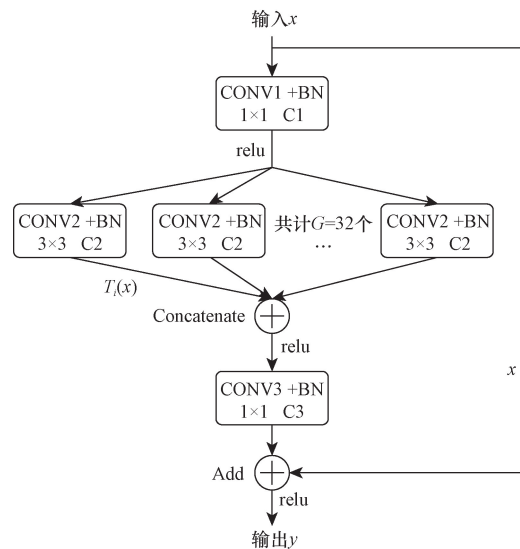


图 1 恒等映射单元

Fig. 1 Identity mapping unit

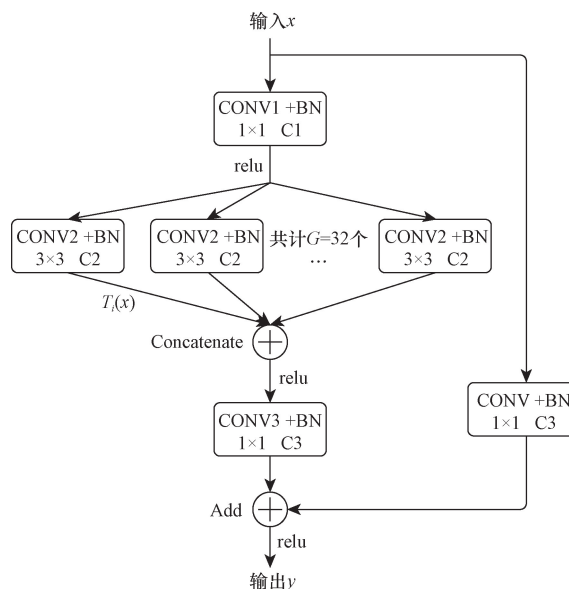


图 2 投影映射单元

Fig. 2 Projection mapping unit

### 1.2.2 ECA 注意力机制

Wang 等<sup>[12]</sup> 提出了一种轻量级的高效通道注意力 (efficient channel attention, ECA) 模块。如图 3 所示, 该模块避免了维度缩减并进行了适当的跨通道交互, 在保持性能的同时显著降低了模型复杂性。在输入尺寸为  $C \times H \times W$  的特征图后, ECA 模块先使用全局平均池化操作聚合卷积特征, 再自适应确定卷积核尺寸  $k$ , 之后进行一维卷积操作, 最后通过 Sigmoid 函数进行通道注意力学习。

ECA 模块通过自适应选择一维卷积核尺寸, 以此确定局部跨信道交互的覆盖率。覆盖率与通道维数存在正比关系。在通道维数  $C$  固定的情况下,




图3 ECA 模块结构

Fig. 3 The structure of ECA module

自适应地确定一维卷积核尺寸  $k$  为

$$k = \varphi(C) = \left\lfloor \frac{\log_2 C}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{odd}} \quad (9)$$

1. 2. 3 改进 ResNeXt 网络单元

在原有 ResNeXt 单元结构的基础上对其进行了部分调整。调整并行支路的卷积核尺寸, 由原先 32 组全部为  $3 \times 3$  结构调整为  $1 \times 1, 3 \times 3, 5 \times 5, 7 \times 7$  各 8 组, 增强了模型的感知力; 在恒等映射单元中嵌入 ECA 注意力模块, 提升了网络获取特征信息的能力。改进后的网络单元结构如图 4、图 5 所示。

2 模型架构设计

基于优化 SGMD 与改进 ResNeXt 神经网络的故

障诊断模型结构如图 6 所示。

首先对振动信号进行标准化处理, 选择采用反正切标准化的方式处理实验数据, 表达式为

$$y = \frac{2}{\pi} \arctan(\theta x) \quad (10)$$

式(10)中:  $x$  为原始数据;  $y$  为经标准化处理后的数据;  $\theta$  为调节参数。经处理后  $y \in [-1, 1]$ 。

对标准化处理后的数据进行优化 SGMD 分解、重组、筛选出有效辛几何组合分量, 将其送入神经网络。网络首层为一个通道数 64、卷积核尺寸  $7 \times 7$  的卷积层, 第二层为尺寸  $3 \times 3$  的最大池化层。接下来是 2 个 Stage, 每个 Stage 包含一个恒等映射单元和一个投影映射单元。在每个 Stage 之间添加了参数为 0.1 的 Dropout 层, 以防止模型发生过拟合现象。最后经全局平均池化层及全连接层进行降维操作, 经 Softmax 分类输出, 完成故障诊断。

3 实验验证与分析

3.1 数据选择与划分

为检验故障诊断模型性能, 使用渥太华大学滚动轴承变工况数据集进行测试。数据集由 SpectraQuest 机械故障模拟器采集得到, 该实验台由电机、AC 驱动器、编码器、联轴器、转子和轴承构成。实

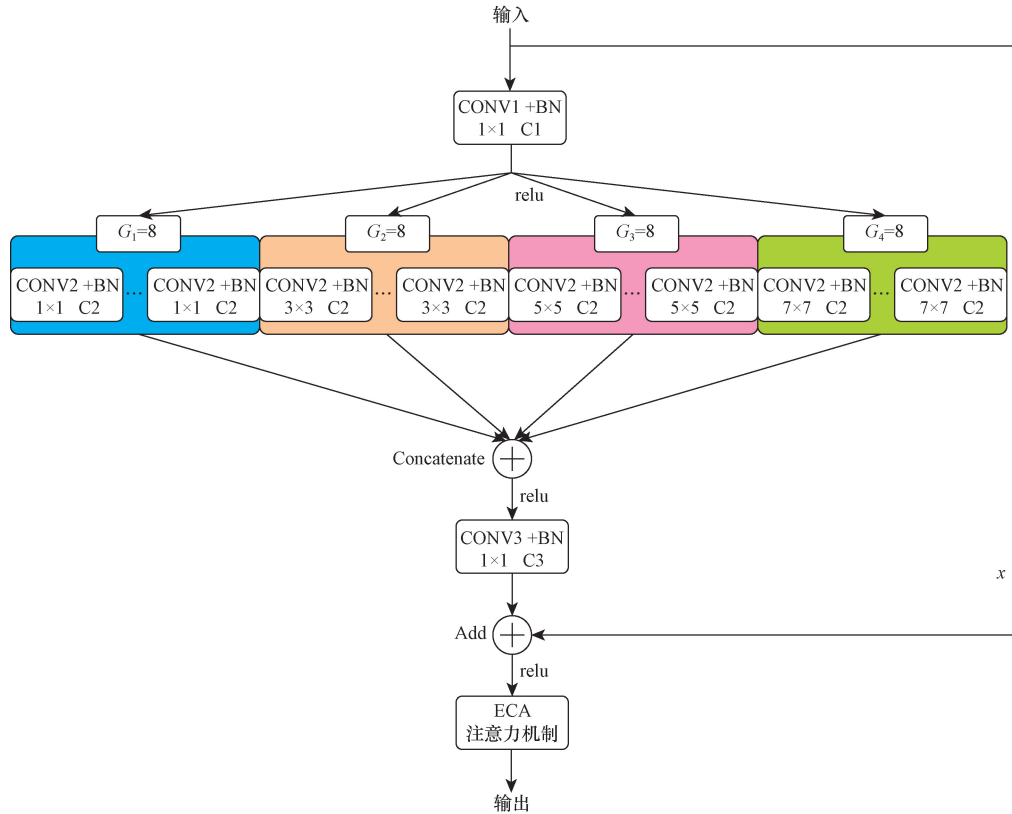


图4 改进 ResNeXt 恒等映射单元

Fig. 4 Identity mapping unit in improved ResNeXt neural network

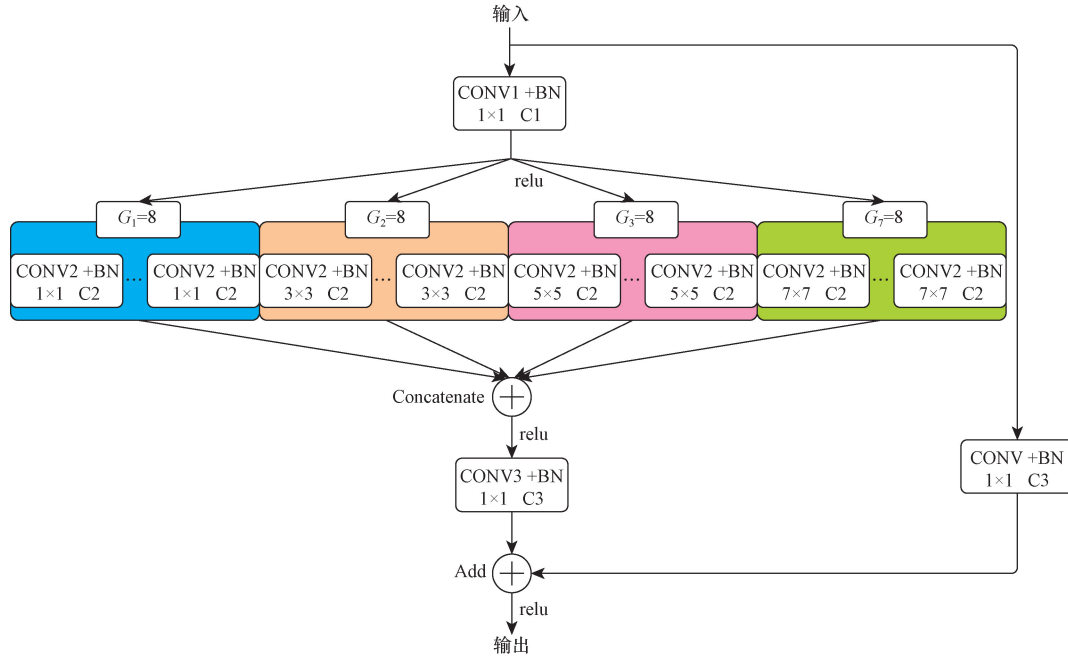


图5 改进 ResNeXt 投影映射单元

Fig. 5 Projection mapping unit in improved ResNeXt neural network

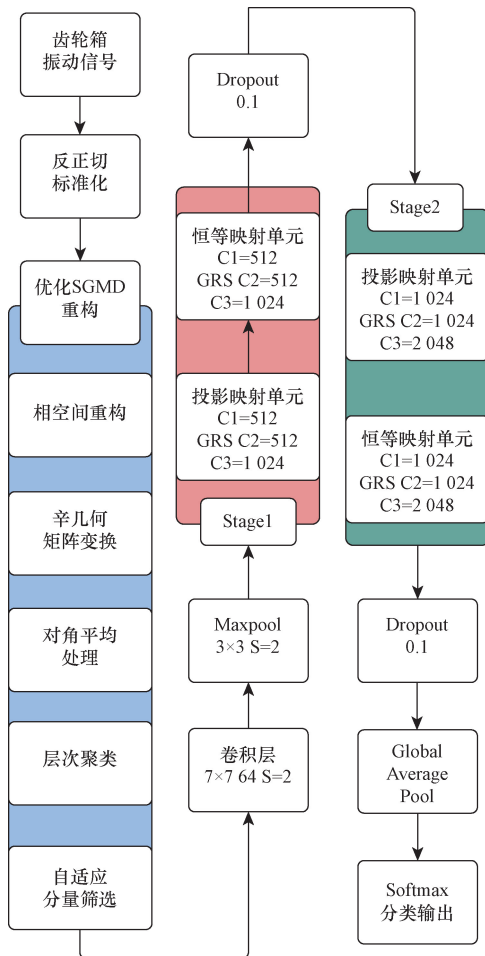


图6 基于优化 SGMD 与改进 ResNeXt 的故障诊断模型

Fig. 6 Fault diagnosis model based on the combination of optimized SGMD and improved ResNeXt neural network

验轴承为 ER16K 球轴承,故障部位有 3 处:轴承外圈、轴承内圈、滚动体。每处分别设置升速、减速、先升速后减速和先减速后升速 4 种工况。实验的采样频率为 200 kHz。

从每个故障部位分别选择 3 种工况,加上正常状态下的升速工况,组成 10 个类别,对应标签 0 ~ 9,其中标签 9 为正常数据。设定每个标签的样本数为 350,按照比例 4:1 划分训练集与测试集,每个样本含有 1 600 个数据点,具体信息如表 1 所示。

本次实验选用 Tensorflow2.7.0 深度学习框架,使用 Python 编程语言,计算机配置为: Intel 酷睿 i9-13980HX CPU,英伟达 GeForce RTX 4070GPU 显卡,16 GB 内存。

表 1 渥太华大学数据集设置

Table 1 Setting of university of Ottawa datasets

标签	故障部位	工况	训练样本数	测试样本数
0		升速	280	70
1	轴承外圈	减速	280	70
2		先升速 后减速	280	70
3		升速	280	70
4	轴承内圈	减速	280	70
5		先升速 后减速	280	70
6		升速	280	70
7	滚动体	减速	280	70
8		先升速 后减速	280	70
9		正常	升速	280

本次实验采用 Adam 优化算法,大小设置为 0.000 1,每批处理量为 32,迭代次数为 50。

### 3.2 优化 SGMD 筛选分量

振动信号经优化 SGMD 分解、重组、筛选后会得到有效相关分量与其他分量,原始信号如图 7 所示,经筛选后有效相关分量与其他分量分别如图 8 与图 9 所示,从中对比发现,相较其他分量,有效相关分量幅值更大,包含的信息量更多。




图 7 原始信号波形图

Fig. 7 Waveform of original signal




图 8 有效相关分量信号波形图

Fig. 8 Waveform of effective correlation component signal




图 9 其他分量信号波形图

Fig. 9 Waveform of other component signal

### 3.3 实验结果

振动信号经训练后,测试集的准确率与损失值变化如图 10、图 11 所示。可以看出模型在不到 10 次迭代内便可达到平稳,此时准确率达到 99.71%,损失值低于 0.01。该模型能够仅需较少的迭代次数便可较好地实现预设目标。T-SNE (t-distributed stochastic neighbor embedding) 算法是一种用于挖掘高维数据的非线性降维算法,能够很好地将高维数据映射到二维空间。采用 T-SNE 算法对模型训练前后分别进行特征可视化分析,结果如图 12、图 13 所示。可以看出,处于混乱状态的原始数据经本文所提模型训练后,无分类错误,故障特征清晰明了。

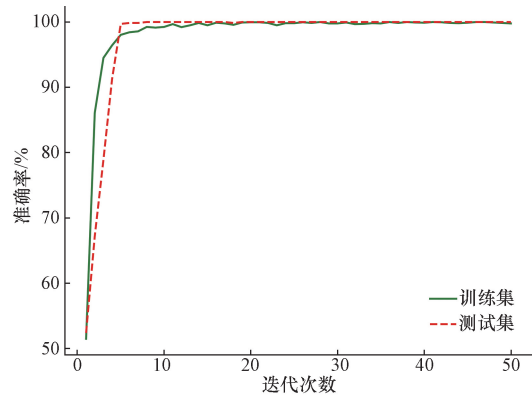


图 10 分类准确率

Fig. 10 Classification accuracy




图 11 分类损失值

Fig. 11 Classification loss

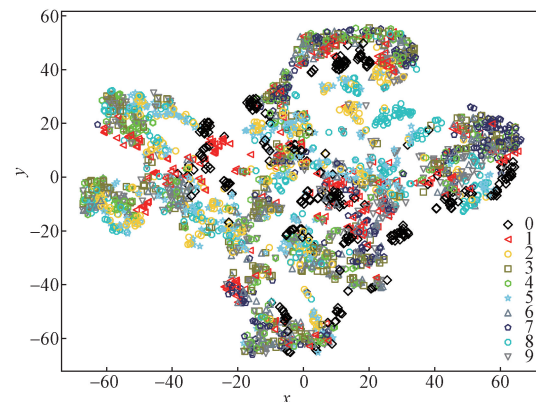


图 12 训练前特征可视化结果

Fig. 12 Feature visualization before training

### 3.4 变工况条件下的故障诊断

#### 3.4.1 实验介绍

选用动力传动故障诊断综合实验台 (drivetrain dynamics simulator, DDS) 数据进行变工况实验, DDS 实验台如图 14 所示。

该实验台由驱动电机、行星齿轮箱、定轴齿轮箱、磁粉制动器等构成。数据采集系统包括各类传感器、采集仪以及驱动软件等。实验的采样频率为

35 kHz,故障类型为8类,对应标签0~7,其中标签7为正常数据。设定每个标签的样本数为350,每个样本含有1 600个数据点,按照比例4:1划分训练集与测试集,具体内容如表2所示。




图13 训练后特征可视化结果

Fig. 13 Feature visualization after training




图14 DDS实验台

Fig. 14 Drivetrain dynamics simulator

表2 DDS实验台数据设置

Table 2 Setting of drivetrain dynamics simulator datasets

标签	故障类型	训练集样本数	测试集样本数
0	齿轮齿面磨损	280	70
1	轴承内圈故障	280	70
2	齿轮缺齿	280	70
3	齿根裂纹	280	70
4	齿轮断齿	280	70
5	轴承外圈故障	280	70
6	轴承滚子磨损	280	70
7	正常	280	70

由于实际工况下采集到的信号极易受到周围环境噪声的影响,对采集到的原始信号,分别添加信噪比为-3、-4.77、-6.99和-10 dB(分别对应模拟采集信号与噪声的平均功率比为1:2、1:3、1:5和1:10)的噪声信号,对模型进行抗噪性检验。

为检验本文所提模型的合理性,进行了模型对比实验。以本文所提模型(优化SGMD+ECA+ResNeXt)为原模型,设置了4个对比模型:使用传统SGMD方法代替优化SGMD的“模型1”、去除优化SGMD模块的“模型2”、去除ECA模块的“模

型3”、使用原版ResNeXt网络的“模型4”,5种模型在不同的模拟实际工况环境下的准确率如图15所示。




图15 不同噪声环境下模型准确率对比

Fig. 15 The comparison of model accuracy in different noise environment

由图15可看出,在高噪声环境下本文所提模型仍能保持着较好的识别准确率,在信噪比为-6.99 dB的环境下,原模型的准确率达到92.56%,且当信噪比增大至-10 dB时,其仍能保持90.41%的模型准确率。在相同噪声环境下,相较使用传统SGMD方法的模型1,本文所提模型的识别准确率更高,且通过对比模型2、3、4发现:优化SGMD模块与ECA模块在提升模型的准确率方面均起到了一定效果。

## 4 结论

本文提出一种基于数据驱动的故障诊断方法,采用信号处理与CNN相结合的方式实现齿轮箱的故障诊断,得出如下结论。

(1) 提出了优化SGMD信号处理方法,该方法在SGMD的基础上通过加入层次聚类和分量信噪比对比,解决了SGMD存在的相似分量重组问题和需要人为的设置迭代终止条件的问题。

(2) 对原有的ResNeXt单元结构进行了改进,并引入了ECA注意力机制,提高了网络的特征提取能力。

(3) 在上述方法的基础上,将二者相结合,提出了优化SGMD与改进ResNeXt神经网络的故障诊断模型。通过使用渥太华大学滚动轴承变工况数据证明了模型的有效性,通过使用DDS实验台数据进行对比实验与抗噪性实验,验证了改进的有效性与该模型的泛化性。该模型在实际工况下能够有效地完成齿轮箱故障诊断任务。

未来会在现有模型的基础上进一步调整模型结构,优化网络参数,缩短训练时间,提升识别精度。

## 参 考 文 献

- [1] 陈科, 段伟建, 吴胜利, 等. 多深度学习模型决策融合的齿轮箱故障诊断分类方法[J]. 科学技术与工程, 2022, 22(12): 4804-4811.  
Chen Ke, Duan Weijian, Wu Shengli, et al. Gearbox fault diagnosis and classification method based on decision fusion of multi-deep learning models[J]. Science Technology and Engineering, 2022, 22(12): 4804-4811.
- [2] 文红权. 基于深度信念网络的故障诊断研究[D]. 北京: 北京交通大学, 2018.  
Wen Hongquan. A fault diagnosis method based on deep belief networks[D]. Beijing: Beijing Jiaotong University, 2018.
- [3] 王金喜. 基于振动信号分析的滚动轴承故障诊断方法研究[D]. 济南: 山东大学, 2024.  
Wang Jinxi. Research on rolling bearing fault diagnosis methods based on vibration signal analysis[D]. Jinan: Shandong University, 2023.
- [4] 张立智, 徐卫晓, 井陆阳, 等. 基于 EMD-SVD 和 CNN 的旋转机械故障诊断[J]. 振动测试与诊断, 2020, 40(6): 1063-1070, 1228.  
Zhang Lizhi, Xu Weixiao, Jing Luyang, et al. Fault diagnosis of rotating machinery based on EMD-SVM and CNN[J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(6): 1063-1070, 1228.
- [5] 崔桂艳, 钟倩文, 郑树彬, 等. 基于 VMD 灰度图像编码和 CNN 的多传感融合轴承故障诊断[J]. 振动与冲击, 2023, 42(21): 316-326.  
Cui Guiyan, Zhong Qianwen, Zheng Shubin, et al. Multi-sensor fusion bearing fault diagnosis based on VMD gray level image coding and CNN[J]. Journal of Vibration and Shock, 2023, 42(21): 316-326.
- [6] 谷娜, 吴胜利, 邢文婷. 基于 PSO-CNN 算法的齿轮故障诊断方法[J]. 科学技术与工程, 2024, 24(26): 11246-11252.  
Gu Na, Wu Shengli, Xing Wenting, et al. Gear fault diagnosis method based on PSO-CNN algorithm[J]. Science Technology and Engineering, 2024, 24(26): 11246-11252.
- [7] 潘海洋. 基于辛几何模态分解和支持矩阵机的机械故障诊断方法[D]. 长沙: 湖南大学, 2019.  
Pan Haiyang. Mechanical fault diagnosis method based on symplectic geometry mode decomposition and support matrix machine[D]. Changsha: Hunan University, 2019.
- [8] 杨宇, 程健, 彭晓燕, 等. 一种基于改进辛几何模态分解的复合故障诊断方法[J]. 湖南大学学报(自然科学版), 2020, 47(2): 53-59.  
Yang Yu, Cheng Jian, Peng Xiaoyan, et al. A composite fault diagnosis method based on improved symplectic geometry modal decomposition[J]. Journal of Hunan University (Natural Sciences), 2020, 47(2): 53-59.
- [9] Lin Y C. Minimax problems under hierarchical structures [J]. Journal of Inequalities and Applications, 2015, 2015: 57.
- [10] 曲海阔, 张哲宇, 刘扬, 等. 一种面向工控联网设备的层次聚类方法[J]. 现代电子技术, 2022, 45(23): 76-82.  
Qu Haikuo, Zhang Zheyu, Liu Yang, et al. Hierarchical clustering method for industrial control networking equipment [J]. Modern Electronics Technique, 2022, 45(23): 76-82.
- [11] Xie S, Girshick R, Dollár P, et al. Aggregated residual transformations for deep neural networks [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2017: 1492-1500.
- [12] Wang Q, Wu B, Zhu P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2020: 11534-11542.