

## 多工况直升机附件齿轮箱振动故障诊断\*

万安平<sup>1</sup>, 龚志鹏<sup>1</sup>, 王景霖<sup>2</sup>, 单添敏<sup>2</sup>, 何家波<sup>1</sup>

(1. 浙大城市学院机械系 杭州, 310015)

(2. 故障诊断与健康管理技术航空科技重点实验室 上海, 201601)

**摘要** 针对直升机附件齿轮箱在有限多工况条件下故障特征提取难度大、识别准确率低等问题, 提出一种结合变分模态分解 (variational mode decomposition, 简称 VMD) 与多尺度卷积神经网络 (multi-scale convolutional neural network, 简称 MCNN) 的故障诊断方法。首先, 对直升机附件齿轮箱进行地面实验和信号采集, 对原始信号进行滤波、降噪等预处理; 其次, 利用 VMD 将信号分解为若干个固有模态 (intrinsic mode functions, 简称 IMF), 依据齿轮副频率特性对分解模态进行重构与归一化, 增强微弱的高频故障特征; 最后, 将重构信号的每个分量视作不同尺度, 经多尺度卷积神经网络进行多尺度特征提取并融合, 由指数归一化分类器给出识别的故障类别。实验结果表明, 所提方法能够有效增强信号故障特征, 挖掘多工况条件下信号的差异性与同一性, 在直升机附件齿轮箱振动故障诊断中平均准确率为 97.25%。

**关键词** 变分模态分解; 多尺度卷积网络; 振动故障诊断; 附件齿轮箱

**中图分类号** V240.2; V232

### 引言

附件齿轮箱 (accessary gear box, 简称 AGB) 是直升机起动系统、润滑系统、燃料系统和液压系统等附属系统的动力传输装置, 其经过一对与径向传动轴连接的锥齿轮从航空发动机的主轴转子获取动力<sup>[1-2]</sup>。由于轻量化要求, 齿轮箱齿轮腹板厚度变薄, 重量减轻, 在复杂的内外激励下容易产生机械振动, 这不仅会产生系统噪声、降低齿轮副的啮合精度与可靠性, 而且会使整个传动系统失效, 导致严重的系统破坏<sup>[3]</sup>。齿轮箱振动故障的表现形式是振动幅值在特定频段超标<sup>[4]</sup>, 针对振动故障诊断研究的主流方法为采用振动信号分析<sup>[5]</sup>, 即采集齿轮箱壳体振动信号, 通过传统的人工信号分析, 提取故障的时域和频域特征<sup>[6]</sup>。这些方法都依赖丰富的信号学知识储备, 诊断结果受人工的影响较大。

随着人工智能技术的不断发展, 基于大数据挖掘的深度学习模型逐渐应用于故障诊断领域。将信号处理与神经网络相结合<sup>[7]</sup>, 利用前者进行数据预处理, 增强信号的故障特征, 利用后者自动提取数据潜藏特征, 满足高效、准确的诊断要求。张立智等<sup>[8]</sup>

将经验模态分解 (empirical mode decomposition, 简称 EMD)、奇异值分解和深度卷积神经网络 (convolutional neural network, 简称 CNN) 结合用于齿轮箱轴承故障诊断与分析, 准确率最高达到了 88.06%。任学平等<sup>[9]</sup>采用 EMD 对原始故障信号进行分解, 经自回归模型特征提取后置入前馈神经网络中识别, 获得了 95% 的准确率。但是 EMD 在分解信号时易出现模态混叠、边界效应等问题, 而 VMD<sup>[10]</sup>作为一种新型自适应信号处理方法, 具有更好的鲁棒性和抗噪性。

CNN<sup>[11]</sup>在高维特征提取方面能力强大, 但其权重共享的特性在处理多传感器数据时, 每个传感器数据的权重分布相同, 使其无法有效地提取多传感器数据的差异性特征。对此, 笔者对不同的传感器采取不同的卷积层, 自适应地提取多尺度信号特征并融合, 以提高特征提取性能。

针对有限变工况下多传感器信号特征提取与识别问题, 本研究提出一种基于 VMD-MCNN 的直升机附件齿轮箱振动故障诊断方法, 采用 VMD 对故障信号进行分解, 并基于齿轮副的频率特性对分离模态进行重构, 进而增强微弱故障特征。

\* 航空科学基金资助项目 (20183333001); 国家自然科学基金资助项目 (52372420); 中国博士后基金特别资助项目 (2018T110587); 浙大城市学院科研培育基金资助项目 (J-202220)

收稿日期: 2022-10-03; 修回日期: 2023-03-30

# 1 VMD-MCNN 模型

直升机附件齿轮箱受内外激励影响,振动故障模式复杂,诊断模型既要保障对振动信号和故障模式之间的复杂映射关系有较强的学习能力,也要保障在变工况与噪声干扰下具备较强的适应能力。对此,笔者提出一种结合 VMD 信号重构与多尺度卷积网络的模型,该模型利用抗噪性能好的 VMD 方法对原始信号进行滤波、分解和重构,由 MCNN 对重构后的信号进行自适应特征提取,并对提取的不同特征进行融合、学习,以增强模型对不同工况与传感器的适应性。VMD-MCNN 网络模型如图 1 所示。




图 1 VMD-MCNN 网络模型  
Fig.1 Network model of VMD-MCNN

## 1.1 变分模态分解原理

VMD 是一种基于 Wiener 滤波的自适应、完全非递归的模态变分和信号处理方法,其将每个 IMF 定义为调幅调频信号,表达式为

$$u_k(t) = a_k(t) \cos(\varphi_k(t)) \quad (1)$$

其中: $a_k(t)$ 为 IMF 瞬时幅值; $\varphi_k(t)$ 为 IMF 瞬时相位。

将原始振动信号  $f$  分解为  $K$  个有限带宽的模态函数  $u_k(t)$ ,使得各个 IMF 的估计带宽之和最小,所有 IMF 的和与原始信号相等。分解过程中每个 IMF 的中心频率与带宽不断更新,直至满足收敛要求,VMD 分解流程如图 2 所示。由图可知,选定合适的分解层数  $K$  值对最终结果具有重要影响。

## 1.2 基于频率特性的信号重构

对于分解后的 IMF s,通过基于齿轮副频率<sup>[6]</sup>特性筛选不同分量进行重新组合,从而将原本特征混叠的一维信号转换为仅包含单一频率特性的多维信号。其过程如下:

- 1) 对于分解的  $K$  个 IMF s,计算齿轮副的输入

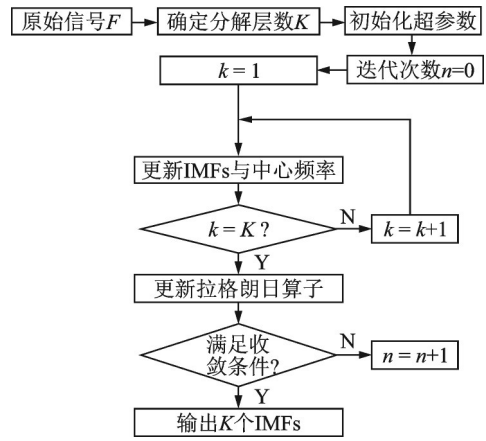


图 2 VMD 分解流程  
Fig.2 VMD decomposition flow chart

轴转频  $f_r$  和啮合频率  $f_c$ ;

- 2) 根据上述计算频率搜索分解后的 IMF s 的中心频率,其中频率接近于  $f_r$  的分量记为  $f_1$ ,频率接近于  $f_c$  的分量记为  $f_2$ ;

- 3) 其余的 IMF s 直接求和记为  $f_3$ ;

- 4) 对得到的 3 个信号分量  $f_1, f_2, f_3$  进行归一化,最终得到幅值分布在  $[0, 1]$  区间的三维信号  $F_{new}$ 。

VMD 分解后的 IMF s 中,低频分量反映了故障信号的宏观特征,如周期性、幅值分布等;高频分量反映了齿轮啮合引起的各机械部件的高频率细微共振,隐含故障的潜在特征。通过 min-max 归一化操作能够将其同步到相同的量级,以增强微弱高频分量在神经网络中的权重,即

$$x_{norm} = (x - x_{min}) / (x_{max} - x_{min}) \quad (2)$$

其中: $x_{norm}$ 为归一化后数据; $x_{min}$ 为对应属性最小值; $x_{max}$ 为对应属性最大值。

## 1.3 多尺度卷积网络

MCNN 为多输入-单输出结构,特征提取层分别对不同通道数据进行提取,提取特征在融合层进行信息融合,不同通道数据包含的故障信息量不同,因此多尺度特征提取的自适应性更高。

笔者提出以齿轮箱外壳体不同采样点位置的传感器作为不同通道,利用 MCNN 对经 VMD 重构后的信号  $x = (x_1, x_2, \dots, x_N)$  进行特征提取,每个尺度的特征提取模块(卷积-池化层)输出提取后的特征为

$$y_i = \max_{i \in R_i^M} \left( f \left( \sum_{m=1}^M W_i \otimes x_i^m + b_i \right) \right) \quad (i = 1, 2, \dots, N) \quad (3)$$

其中: $x_i$ 为第  $i$  个传感器对应的重构信号  $F_{new}$ ;  $f(\cdot)$  为

非线性激活函数; $\otimes$ 为互相关运算; $R_l^M$ 为局部感受野; $l$ 为提取信号长度(本研究取 1 024 个样本点); $M$ 为重构信号维度,本研究  $M = 3$ ;  $N$ 为传感器数量。

特征融合层对特征进行融合后,得到特征矩阵  $y = (y_1, y_2, \dots, y_n)$ ,然后由高维卷积层 A、卷积层 B 对融合后特征进一步提取。

### 1.4 模型结构及参数

诊断模型由  $N$  个并联的多尺度特征提取层、1 个特征融合层、1 个高维特征提取层、1 个展平层和输出层组成,其中每个多尺度特征提取模块由 1 个 VMD 分解模块和 2 个卷积-池化层堆叠,高维特征提取层由 2 个等宽卷积层和 1 个池化层组成。

卷积层采用的激活函数为 ReLU,为防止参数过大引起过拟合的现象,在每一层卷积层均添加 L2 正则化优化方法,并且在卷积层与池化层、展平层与输出层之间添加 Dropout 优化层。特征融合层按照传感器通道方向对提取的多尺度特征进行并联操作。展平层将上层提取的高维特征映射展平为一维,转化为能够输入全连接层的结构。输出层为 1 个全连接层,其采用 softmax 激活函数求取每个故障类别的识别概率,取最大的概率对应的类别标签作为模型诊断结果。

模型的结构参数按照金字塔模式(底部模型核数少,顶部模型核数多)设定参数,以 16 为基准不断增大网络层核数,直到模型训练的准确率增量小于 0.1% 时停止调整,选定此时的参数为最终优化模型的结构参数,如表 1 所示。

表 1 模型参数  
Tab.1 Model parameters

模块名称	层名	核尺寸	输出大小
多尺度特征提取模块	卷积层	$(3 \times 1, 32) \times N$	$1024 \times 32$
	池化层	$(3 \times 2, 32) \times N$	$512 \times 32$
	卷积层	$(3 \times 1, 64) \times N$	$512 \times 64$
	Dropout 层	$(1 \times 1, 64) \times N$	$512 \times 64$
特征融合	池化层	$(3 \times 2, 64) \times N$	$256 \times 64$
	融合层	$(1 \times 1, 320) \times 1$	$256 \times 320$
	全连接层	$(1 \times 1, 32) \times 1$	$256 \times 32$
高维特征提取层	卷积层 A	$(3 \times 1, 64) \times 1$	$256 \times 64$
	池化层	$(3 \times 2, 64) \times 1$	$128 \times 64$
	卷积层 B	$(3 \times 1, 64) \times 1$	$128 \times 64$
故障分类	展平层	$(1 \times 1, 1) \times 1$	$8192 \times 1$
	Dropout 层	$(1 \times 1, 1) \times 1$	$8192 \times 1$
	全连接层	$(1 \times 1, 6) \times 1$	$6 \times 1$

## 2 基于 VMD-MCNN 的故障诊断方法

采用 VMD-MCNN 模型对直升机附件齿轮箱进行故障诊断,方法流程如图 3 所示,具体步骤如下。

1) 数据采集:在直升机附件齿轮箱外壳体不同位置和方向安装多个加速度传感器,采集不同尺度的振动信号。

2) 信号处理:对采集的多传感器信号分别进行 VMD 分解,并基于齿轮副频率特性进行信号重组,对重组后的信号分量进行归一化。

3) 离线训练:将重构信号样本划分为训练集和测试集,初始化卷积神经网络的权重、偏置为接近于 0 的随机数,设置模型训练的迭代次数、学习率以及优化方法。以小批量的形式输入样本到 MCNN 网络中,逐层进行前向传播获取故障特征,于输出层获取预测故障类别,计算真实样本类别与预测值的误差,反向传播计算误差梯度,更新网络参数。

4) 模型测试:将未经训练的测试样本(类别标签未知)输入模型进行识别诊断,将诊断结果与真实类别进行比较,计算模型准确率。

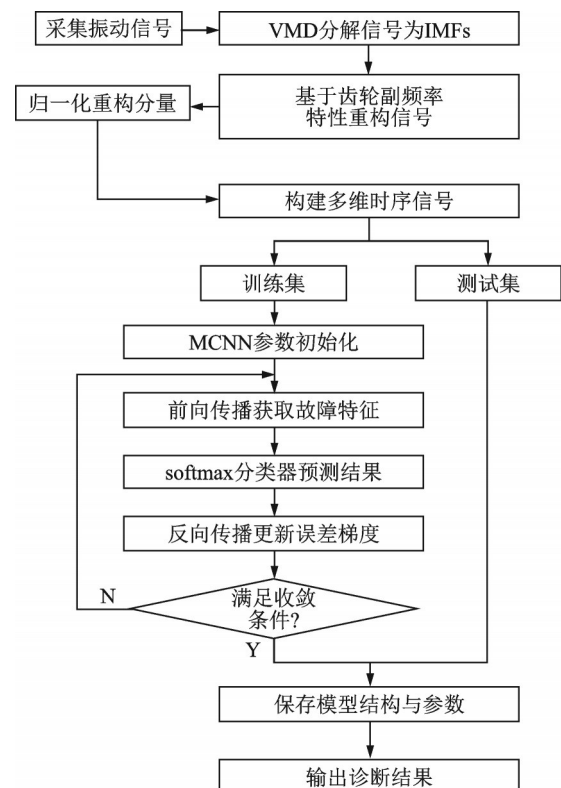


图 3 方法流程图

Fig.3 Flow chart of method



### 3 实验验证

#### 3.1 数据采集

数据采集实验台为图 4 所示的直升机行星传动仿真实验平台,主要由变速驱动电机、2 级行星齿轮箱、平行齿轮箱和可编程磁力制动器组成。

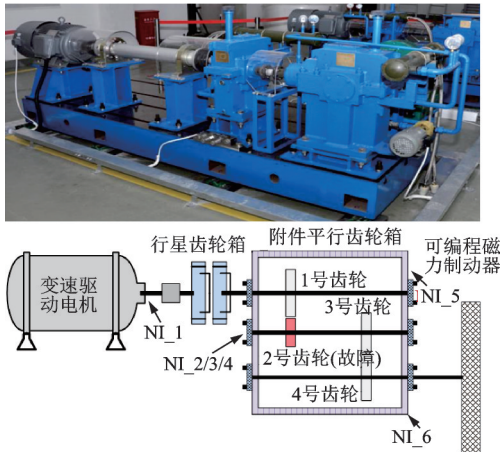


图 4 直升机行星传动仿真实验平台

Fig.4 Helicopter planetary gearboxes transmission platform

实验设置 6 种齿轮故障模式:正常齿轮、轮齿折断、缺齿、齿面磨损、齿根裂纹和偏心轮。故障齿轮如图 5 所示。在平行齿轮箱外侧安装加速度传感器来检测振动信号,采样频率为 51 200 Hz,齿轮箱故障测点布置如表 2 所示。



图 5 故障齿轮

Fig.5 Faulty gear

表 2 齿轮箱故障测点布置

类型	采集仪对应位置	测点位置
转速计	NI-1	驱动电机输出轴
加速度 1	NI-2(轴向)	平行齿轮箱中间轴 轴承端盖
加速度 2	NI-3(水平径向)	
加速度 3	NI-4(垂直径向)	
加速度 4	NI-5	平行齿轮箱右侧箱体
加速度 5	NI-6	承重台面-靠平行齿轮箱

为模拟直升机附件齿轮箱在翼时转速微弱波动与负载大范围变化的工作状态,对每种故障模式均

设置 4 种工况,不同工况下的样本配置见表 3。

表 3 不同工况下的样本配置

编号	转频/Hz	负载/(N·m)	故障模式	样本量	样本点数
1	34	22	6	18 000	1 024
2	34	44	6	18 000	1 024
3	57	22	6	18 000	1 024
4	57	44	6	18 000	1 024

#### 3.2 信号处理

对实验采集的振动加速度信号进行 VMD 分解,根据齿轮副频率特性对分解的模态进行重构,并增强微弱故障特征。

由于分解层数  $K$  对 VMD 模态分解的影响很大,分解层数过多,相邻 2 个分量对应的中心频率相差较小,产生过分解现象;分解层数较少,不同中心频率对应的分量未能分离,出现欠分解现象。本研究通过逐渐增大  $K$  值,观察分解后各个分量  $u$  之间是否存在过分解与欠分解现象,来确定分解次数<sup>[12]</sup>。

表 4 为不同  $K$  值对应的 IMF 中心频率,由表可知:当  $K=5$  时,频率为 118 Hz 的分量没有被分解,存在欠分解现象;当  $K=7$  时,  $u_4$  与  $u_5$  的中心频率与  $K=6$  时的  $u_4$  频率十分接近,存在过分解现象。因此,确定分解层数  $K$  为 6,最终的 VMD 分解结果如图 6 所示。

表 4 不同  $K$  值对应的 IMF 中心频率

$K$	$u_1$	$u_2$	$u_3$	$u_4$	$u_5$	$u_6$	$u_7$
3	11	25	181	—	—	—	—
4	11	23	39	182	—	—	—
5	12	23	39	182	355	—	—
6	12	23	39	118	184	358	—
7	12	22	39	88	125	185	359

由图 6 可知:  $u_1$  的中心频率接近于齿轮副输入轴转频(11.398 Hz);  $u_6$  的中心频率接近于齿轮副啮合频率(330.540 Hz)。根据 1.2 节的信号重构流程,得到的信号重构结果如图 7 所示。

#### 3.3 模型训练

实验中模型训练使用 Adam 优化算法更新网络参数并控制网络的学习率,初始学习率设为 0.000 1。

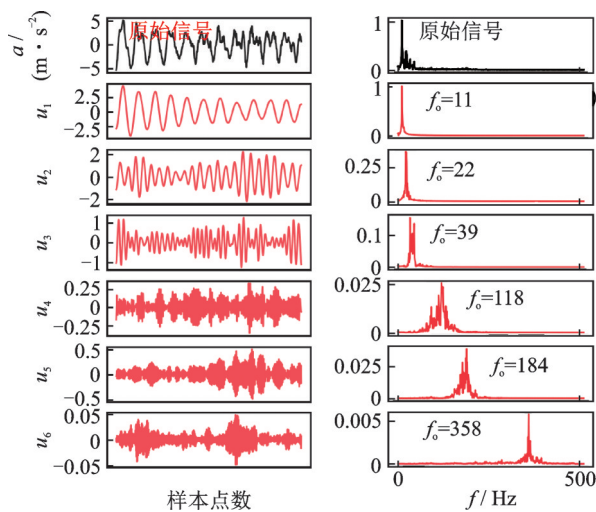


图6 VMD分解结果

Fig.6 Result of VMD




图7 信号重构结果

Fig.7 Results of signal reconstruction

针对训练回合数选择,采取早停法,当模型的损失函数(误差)下降速率小于 $1 \times 10^{-3}$ ,且稳定保持5个回合时,提前中止模型训练,保存此刻模型参数。

模型训练在配置 NVIDIA GeForce GTX1650 和 16-GB RAM 的计算机上实施。编程语言为 Python,集成开发环境为 Spyder, TensorFlow 2.1.1 和 Keras 2.3.1。采用准确率对诊断模型识别效果进行评价,训练过程损失函数采用交叉熵损失函数。

实验将数据以 4:1 划分为训练样本(训练集、验证集)和测试样本,模型训练过程如图 8 所示。

### 3.4 测试结果分析与讨论

考虑到实验安装的 5 个加速度传感器并不都能准确捕捉齿轮故障引起的箱体振动变化,传感器数量及其布置位置对诊断效果会产生很大影响,本研究采用包裹法来确定传感器数量  $N$ ,即设定一个空间集合,从 1~5 依次向该集合中增添传感器数量,比较各个传感器对模型准确率的影响。实验得到的传感器集合对模型效果的影响如图 9 所示。

结果表明,增大传感器数量  $N$  不仅不会提升模

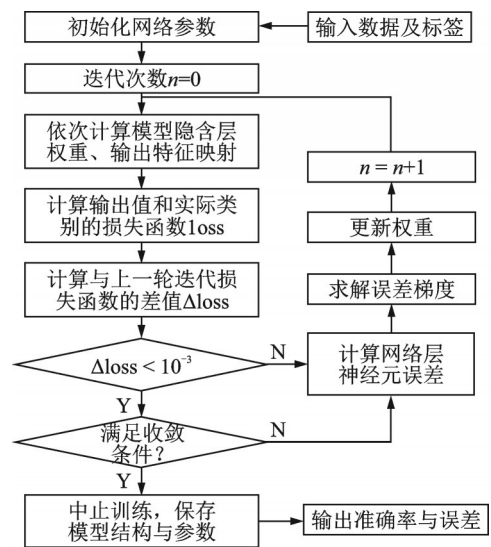


图8 模型训练过程

Fig.8 Model training process




图9 传感器集合对模型效果的影响

Fig.9 Effect of sensor set on model

型的准确率,还可能引入无关信息致使模型复杂度提升,从而降低了诊断精度。由图 9 可知,NI\_346 的传感器集合训练集与测试集准确率高,泛化性能最好,这 3 个传感器均为安装在靠近齿轮箱壳体或直接附着在壳体表面,对于故障信息的采集更为精确,因此以该集合构建模型的输入结构。

以传感器集合为 NI\_346,建立 3 个并行多尺度特征提取模块的诊断模型并进行训练,其训练过程损失函数和准确率变化如图 10 所示。训练集和验证集的损失函数与准确率在训练过程中同时变化,在 16 回合达到收敛,保存此时的模型参数。

为了验证所提方法的优越性,将该方法与其他相关诊断方法进行对比,包括决策树(DT)<sup>[12]</sup>、支持向量机(SVM)<sup>[13]</sup>、一维卷积网络(1D-CNN)、残差网络(ResNet)<sup>[14]</sup>、短时傅里叶变换-卷积(STFT-CNN)<sup>[15]</sup>、连续小波变换-卷积(CWT-CNN)<sup>[16]</sup>以及经验模态分解-多尺度卷积(EMD-MCNN)<sup>[8]</sup>。重复实验 10 次,所有模型均选择最优设置下的结果作为实验结果,




图 10 训练过程损失函数和准确率变化

Fig.10 Loss function and accuracy change during training

不同诊断方法在齿轮箱测试集的准确率分布见图 11,其中:红色实线为中位数;蓝色虚线为均值;红点为离群值。

图 11 左图为单一模型(未采用信号处理),右图为信号处理与神经网络混合方法。从准确率来看,混合方法对输入信号进行了特征增强与解析,极大提升了模型的诊断效果。本研究提出的 VMD-MCNN 平均准确率为 97.25%,远高于单一模型的识别效果,虽然准确率最高值不及 EMD-MCNN,但多次实验的结果较为稳定,方差较小,鲁棒性较强。




图 11 不同诊断方法在齿轮箱测试集的准确率分布

Fig.11 Distribution of accuracy of different diagnostic methods in gearbox test set

为了检验多尺度特征提取 CNN 模块对多传感器振动故障信号特征提取的影响,本研究将模型识别准确率与仅采用单尺度特征提取 CNN 模块的模型(SCNN)进行了对比,模型结构及归一化操作对结果的影响如表 5 所示。可以看出,多尺度 CNN 在每个工况下效果均优于单尺度 CNN,准确率分别提升了 8.367%,5.975%,1.408% 和 4.617%,说明针对不同传感器尺度的自适应特征提取能够更完整地获取故障特征。

表 5 模型结构及归一化操作对结果的影响

Tab.5 Influence of model structure and normalization operation on results %

工况	SCNN	未归一化	MCNN(归一化)
1	91.500	81.834	96.867
2	92.958	86.467	98.933
3	97.425	95.000	98.833
4	91.250	95.066	95.867

为了检验 VMD 分解信号及重构之后对不同重构分量数值区间归一化操作带来的模型提升效果,本研究将未归一化的原始分量输入模型进行训练,模型结构及归一化操作对结果的影响如表 5 所示。未归一化时,工况 3,4 由于转频和负载增大使故障信号频率与幅值增大,导致模型在训练时更倾向于学习该工况下的数据特征,使工况 1,2 的诊断准确率较低。归一化后,这种数值差异消除,工况之间的特征空间统一,模型的学习效果和工况稳定性明显提升。

## 4 结 论

1) 传感器的数量与安装位置决定了齿轮箱机体振动故障信息的清晰度,过多的传感器无法显著提升诊断效果,反而会造成信息冗余,增大数据维度和模型复杂度,对模型识别效果产生阻碍作用。

2) 故障信号经 VMD 和归一化方法重构后,微弱故障特征得以增强,多工况数据特征的同伦性被提取,提升了模型准确率及工况的适应性和稳定性。

3) 多尺度卷积网络对多传感器信号自适应特征提取,并基于特征层信息融合能够丰富故障特征,在一定程度上提升模型的诊断效果。

## 参 考 文 献

[1] 林基恕. 航空发动机设计手册: 第 12 册[M]. 北京: 航空工业出版社, 2002:12-16.

[2] HOOD A A. Fault detection on a full-scale OH-58 A/C helicopter transmission [D]. Maryland: University of Maryland, 2010.

[3] 庞新宇, 魏子涵, 仝钰. 基于 SCGAN 网络的齿轮故障诊断方法[J]. 振动、测试与诊断, 2022, 42(2): 358-364.

PANG Xinyu, WEI Zihan, TONG Yu. Fault diagnosis method of gear based on SCGAN network[J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(2): 358-364.(in Chinese)



- [4] ZHOU X, LU F, HUANG J Q. Fault diagnosis based on measurement reconstruction of HPT exit pressure for turbofan engine[J]. Chinese Journal of Aeronautics, 2019, 32(5): 1156-1170.
- [5] 余晓霞, 汤宝平, 魏静, 等. 强背景噪声条件下自适应图卷积神经网络的航空发动机附件机匣故障诊断方法[J]. 仪器仪表学报, 2021, 42(8): 78-86.  
YU Xiaoxia, TANG Baoping, WEI Jing, et al. Fault diagnosis for aero-engine accessory gearbox by adaptive graph convolutional networks under intense background noise conditions[J]. Chinese Journal of Scientific Instrument, 2021, 42(8): 78-86.(in Chinese)
- [6] 王景霖, 曹亮, 沈勇, 等. 航空发动机滚动轴承故障特征频率研究[J]. 自动化与仪表, 2021, 36(7): 58-63.  
WANG Jinglin, CAO Liang, SHEN Yong, et al. Research on fault feature frequency of aero-engine rolling bearing[J]. Automation & Instrumentation, 2021, 36(7): 58-63.(in Chinese)
- [7] GAO Z W, CECATI C, DING S X. A survey of fault diagnosis and fault-tolerant techniques—part I: fault diagnosis with model-based and signal-based approaches [J]. IEEE Transactions on Industrial Electronics, 2015, 62(6): 3757-3767.
- [8] 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.  
ZHANG Lizhi, XU Weixiao, JING Luyang, et al. Fault diagnosis of rotating machinery based on EMD-SVD and CNN[J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(6): 1063-1070.(in Chinese)
- [9] 任学平, 霍灿鹏. 基于EMD-AR谱和GA-BP的滚动轴承故障诊断研究[J]. 机电工程, 2021, 38(7): 892-896.  
REN Xueping, HUO Canpeng. Fault diagnosis of rolling bearing based on EMD-AR spectrum and GA-BP [J]. Journal of Mechanical & Electrical Engineering, 2021, 38(7): 892-896.(in Chinese)
- [10] 陈龙, 史文库, 陈志勇, 等. 基于小波-VMD联合降噪的传动系扭振信号分析[J]. 振动、测试与诊断, 2022, 42(4): 703-709.  
CHEN Long, SHI Wenku, CHEN Zhiyong, et al. Analysis of torsional vibration signal of transmission system based on wavelet-VMD joint de-noising[J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(4): 703-709.(in Chinese)
- [11] 何成兵, 王润泽, 张霄翔. 基于改进一维卷积神经网络的汽轮发电机组轴系扭振模态参数辨识[J]. 中国电机工程学报, 2020, 40(supp1): 195-203.  
HE Chengbing, WANG Runze, ZHANG Xiaoxiang. Modal parameters identification of torsional vibration of turbogenerator shafting based on improved one-dimensional convolution neural network [J]. Proceedings of the CSEE, 2020, 40(supp1): 195-203.(in Chinese)
- [12] HUNT E B, MARIN J, STONE P J. Experiments in induction [M]. Washington: Academic Press, 1966: 23-26.
- [13] 高坤明, 张衡, 张振京, 等. 基于时频分析和SVM的发动机齿轮箱故障诊断[J]. 机电工程技术, 2022, 51(3): 287-291.  
GAO Kunming, ZHANG Heng, ZHANG Zhenjing, et al. Design of active suspension sliding mode controller based on multi-objective genetic algorithm[J]. Mechanical & Electrical Engineering Technology, 2022, 51(3): 287-291.(in Chinese)
- [14] 王崇宇, 郑召利, 刘天源, 等. 基于卷积神经网络的汽轮机转子不平衡与不对中故障检测方法研究[J]. 中国电机工程学报, 2021, 41(7): 2417-2427.  
WANG Chongyu, ZHENG Zhaoli, LIU Tianyuan, et al. Research on detection method of steam turbine rotor unbalance and misalignment fault based on convolution neural network [J]. Proceedings of the CSEE, 2021, 41(7): 2417-2427.(in Chinese)
- [15] 朱沁玥, 何海昊, 李锋, 等. 基于短时傅里叶变换和深度卷积神经网络的直升机齿轮箱故障诊断方法[J]. 失效分析与预防, 2022, 17(1): 1-8.  
ZHU Qinyue, HE Haihao, LI Feng, et al. A fault diagnosis method of helicopter gearbox based on short-time fourier transform and deep convolutional neural network [J]. Failure Analysis and Prevention, 2022, 17(1): 1-8.(in Chinese)
- [16] 陈仁祥, 黄鑫, 杨黎霞, 等. 基于卷积神经网络和离散小波变换的滚动轴承故障诊断[J]. 振动工程学报, 2018, 31(5): 883-891.  
CHEN Renxiang, HUANG Xin, YANG Lixia, et al. Rolling bearing fault identification based on convolution neural network and discrete wavelet transform[J]. Journal of Vibration Engineering, 2018, 31(5): 883-891.(in Chinese)



**第一作者简介:** 万安平,男,1983年11月生,博士、副教授。主要研究方向为复杂装备健康管理及维修决策等。  
E-mail: wanap@hzc.edu.cn

**通信作者简介:** 何家波,男,1986年2月生,博士、助理研究员。主要研究方向为复杂设备故障诊断与智能制造。  
E-mail: jiabohe@zju.edu.cn