

形态经验小波变换和改进分形网络在轴承故障识别中的应用

杜小磊^{1,2}, 陈志刚^{1,2}, 王衍学^{1,3}, 张楠¹

(1. 北京建筑大学机电与车辆工程学院, 北京 100044; 2. 北京市建筑安全监测工程技术研究中心, 北京 100044;
3. 北京建筑大学城市轨道交通车辆服役性能保障北京市重点实验室, 北京 100044)

摘要: 传统滚动轴承故障识别方法过度依赖专家经验且故障特征提取与选择较为复杂, 提出一种基于形态经验小波变换(MEWT)和改进分形网络(IFractalNet)的识别方法。利用 MEWT 将滚动轴承振动信号自适应分解为若干本征模态分量; 根据综合评价指标选择包含明显故障特征的本征模态分量并重构; 针对原始分形网络的缺陷改进其损失函数和激活函数; 将重构后的轴承振动信号输入 IFractalNet 进行自动特征提取与故障识别。实验结果表明: 所提方法避免了复杂的人工特征提取过程, 能够有效地对滚动轴承进行多种故障类型和多种故障程度的识别, 在泛化能力、特征提取能力和故障识别能力方面具有明显优势。

关键词: 故障识别; 滚动轴承; 形态经验小波变换; 分形网络

中图分类号: TH165+.3; TH133.33 **文献标志码:** A **文章编号:** 1004-4523(2021)03-0654-09

DOI: 10.16385/j.cnki.issn.1004-4523.2021.03.024

引言

滚动轴承作为旋转机械的重要部件, 其对整机的性能和稳定性都有一定影响, 因此对滚动轴承进行及时监测诊断具有重要意义^[1]。

然而, 由于滚动轴承振动信号传递路径比较复杂, 多个振源的激励和响应相互耦合, 且又容易受到外界环境噪声干扰, 使得所测得信号的信噪比较低, 呈现出明显的非线性和非平稳性。为了获得更好的故障识别结果, 需要对轴承原始振动信号进行预处理以增强其故障特征信息。由文献[2]可知, 经验模态分解、集合经验模态分解、局部均值分解等方法存在模态混叠、端点效应和虚假分量等问题; 变分模态分解模态分量个数难以确定。经验小波变换^[3](empirical wavelet transform, EWT)具有完备的数学理论, 通过分割信号频谱并构造合适的小波滤波器提取不同的模态分量, 分解结果更稳定, 但目前存在的 4 种边界检测法: 局部极大值法、局部极大极小值法、自适应法和尺度空间法均会使得某些频率成分无法分离。

深层卷积神经网络^[4](DCNN)作为深度学习的一种典型算法, 在机械故障诊断领域得到了广泛的应用。Chen 等^[5]将小波变换时频图像直接输入

DCNN, 实现了齿轮箱的自动故障识别; Wang 等^[6]将 STFT 时频图像与 DCNN 应用于电机故障识别, 取得了较高的精确度。但有研究^[7-8]表明, 若 DCNN 层数较低, 则模型难以表征轴承振动信号与轴承故障之间复杂的映射关系; 随着层数的加深, 会出现故障识别率先上升然后迅速降低的问题, 这是因为当层数加深时, 梯度在传播过程中会逐渐消失, 导致无法对前面几层的权重进行调整, DCNN 训练难度不断加大, 很难保证模型能训练到一个理想的结果。而 FractalNet 通过选择合适的子路径集合提升模型表现, 较好地解决了 DCNN 模型反向传播时梯度消散的问题, 降低了训练深层模型的难度, 并可加快实际训练过程中模型的收敛速度。本文将 FractalNet 引入滚动轴承故障识别领域, 并针对因滚动轴承故障样本不平衡造成 FractalNet 识别率低的问题, 改进原始 FractalNet 的损失函数, 对样本较多的故障类别赋以较小权重, 对样本较少的类型赋以较大的权值; 并将 Fisher 惩罚项引入 FractalNet, 利用 Fisher 惩罚项, 使 FractalNet 学习到的隐层特征对振动信号的结构变化具有可区分性; 为缓解 ReLU 函数造成的“神经元死亡”现象, 将 GELU 作为 FractalNet 的激活函数。

本文针对 EWT 和 FractalNet 的优势, 提出一种形态经验小波变换(morphological empirical wavelet

收稿日期: 2019-06-22; **修订日期:** 2020-01-22

基金项目: 国家自然科学基金资助项目(51605022, 51875032); 北京市教育委员会科技计划一般项目(SQKM201710016014); 北京市优秀人才培养资助项目(2013D005017000013); 北京市属高校基本科研业务费专项资金资助项目(X18217)

transform, MEWT)和改进分形网络(improved FractalNet, IFractalNet)的滚动轴承故障识别方法,并通过实验证明提出方法的可行性和有效性。

1 MEWT

EWT分割轴承振动信号的频谱,通过小波滤波器提取不同频段的调幅-调频成分,从而将信号分解为 N 个单分量模态函数之和。本文对EWT进行两方面改进:(1)辅助白噪声法优化EWT;(2)利用形态滤波提取振动信号频谱中具有显著特征的局部极大值作为谱划分边界。

1.1 辅助白噪声法优化EWT

由完备集合经验模式分解(CEEMD)^[9],正负白噪声对在降低信号重构误差方面效果显著,本文提出辅助白噪声法优化EWT,具体步骤如下:

(1)向轴承振动信号 $x(t)$ 中加入符号相反、均值为0、标准差为 std 的高斯白噪声,得到 $x_{i1}(t)$ 和 $x_{i2}(t)$ 。

$$\begin{cases} x_{i1}(t) = x(t) + noise_i(t) \\ x_{i2}(t) = x(t) - noise_i(t) \end{cases}, i = 1-N \quad (1)$$

(2)对上述 $x_{i1}(t)$, $x_{i2}(t)$ 进行EWT分解,得到2组imfs:

$$\begin{cases} imf1_{ij}(t), j = 1-k \\ imf2_{ij}(t), j = 1-k \end{cases} \quad (2)$$

式中 $imf1_{ij}(t)$ 为 $x_{i1}(t)$ 第 i 次分解后第 j 个imf分量; $imf2_{ij}(t)$ 为 $x_{i2}(t)$ 第 i 次分解后第 j 个imf分量。

(3)重复步骤(1)和(2),且每次循环加入新的高斯白噪声对。

(4) N 次循环后将 $2 \times N \times k$ 个imfs集成平均 $imf_j(t) = \frac{1}{2N} \sum_{i=1}^N [imf1_{ij}(t) + imf2_{ij}(t)]$, $j = 1-k$ (3)

式中 $imf_j(t)$ 为所有分解结果第 j 层imf分量的均值。

(5)重构信号,得到 $x_0(t)$

$$x_0(t) = \sum_{i=1}^k imf_j(t), j = 1-k \quad (4)$$

1.2 形态滤波划分频谱边界

轴承振动信号频谱划分的合理性直接影响EWT的分解质量,频带划分不合理将引起模态混叠或过分解,导致信号有效信息的缺失,因此本文提出形态学EWT分解方法,实现更精确的EWT自适应模态分解。首先获取轴承振动信号的频谱包络,统计包络有效局域极大值点,作为信号频谱划分边界。由文献[10],获取信号频谱包络等同于对包络低通滤波,而形态滤波具有快速全局非线性滤波特

性,能有效抑制高频噪声。其基本运算包含“膨胀 \oplus ”和“腐蚀 \ominus ”,计算公式为

$$(x \oplus b)(n) = \max[x(n-m) + b(m)] \quad (5)$$

$$(x \ominus b)(n) = \min[x(n+m) - b(m)] \quad (6)$$

式中信号 $x(n)$ 和 $b(n)$ 分别为定义在 $F = (0, 1, \dots, N-1)$ 和 $G = (0, 1, \dots, M-1)$ 上的离散函数,且 $N \geq M$ 。为避免“膨胀”运算造成振动信号变形过大而引起信息丢失的问题,采用先“膨胀”再“腐蚀”的复合形态闭运算对所获取的包络进行修正,形态闭运算“ \cdot ”如下

$$(x \cdot b)(n) = (x \oplus b \ominus b)(n) \quad (7)$$

由文献[11],结构元素 b 应与轴承振动信号形态相似,考虑振动信号频谱形状,采用椭圆形结构元素,其参数主要包括:幅度 h_m 和宽度 w_m , h_m 与滤波结果平滑度成反比, w_m 与滤波结果平滑度成正比。形态滤波算法在保留振动信号频谱信息基础上,提取信号频谱中具有显著特征的局部极大值,结构元素 b 的参数参考值设置如下

$$\begin{cases} h_m = a_h \times 0.1 \times A_a \\ w_m = a_w \times f_{dmin} \end{cases} \quad (8)$$

式中 A_a 为轴承振动信号幅度均值, f_{dmin} 为最小分辨率频宽, a_h 和 a_w 为修正系数,一般设置为1。最后将包络的局部极大值按降序排列, $(M_1 \geq M_2 \geq \dots \geq M_M)$,包括0和 π ,取 $M_M + a(M_1 - M_M)$ 为阈值,其中 a 为相对振幅比, $0 < a < 1$ 。对于确定的 a ,可以令大于阈值的极大值点个数为 N ,并取前 N 个最大的极大值点求边界,求出边界后, N 个区间段中的每一段都可表示为 $A_n = [M_{n-1}, M_n]$,经反复实验,本文取 $a = 0.2$ 。由此可得到所有的区间边界, M_n 为第 n 个边界,经验小波的母小波定义为 A_n 上的带通滤波器,经验尺度函数 $\hat{\varphi}_n(\omega)$ 和经验小波函数 $\hat{\psi}_n(\omega)$ 通过文献[3]计算。由此可得EWT的细节系数和近似系数:

$$W_x^\varepsilon(x, t) = \langle x, \psi_n \rangle = F^{-1}(\hat{x}(\omega) \overline{\hat{\psi}_n(\omega)}) \quad (9)$$

$$W_x^\varepsilon(0, t) = \langle x, \varphi_1 \rangle = F^{-1}(\hat{x}(\omega) \overline{\hat{\varphi}_1(\omega)}) \quad (10)$$

信号重建公式如下式所示

$$x(t) = W_x^\varepsilon(0, t) * \varphi_1(t) + \sum_{n=1}^{N-1} W_x^\varepsilon(n, t) * \psi_n(t) \quad (11)$$

式中 $*$ 代表卷积操作,则信号 $x(t)$ 可被分解为:

$$x_0(t) = W_x^\varepsilon(0, t) * \varphi_1(t) \quad (12)$$

$$x_k(t) = W_x^\varepsilon(k, t) * \psi_k(t) \quad (13)$$

式中 $k = 1, 2, \dots, N-1$ 。

1.3 仿真信号分析

设置仿真信号 $x(t)$ 由4个分量叠加,如下式所示

$$\begin{cases} x(t) = x_1(t) + x_2(t) + x_3(t) + x_4(t) \\ x_1(t) = \cos(30\pi t) \\ x_2(t) = 0.6\cos[50\pi t - 4\cos(10t)] \\ x_3(t) = 0.3\cos[80\pi t - 6\cos(10t)] \\ x_4(t) = \text{randn}(n) \end{cases} \quad (14)$$

式中 $x_1(t)$ 为余弦信号, $x_2(t)$ 和 $x_3(t)$ 为调频信号, $x_4(t)$ 为高斯白噪声。

分别采用 MEWT 和原始 EWT 对 $x(t)$ 进行分解, 并取与 $x(t)$ 相关性较强的前 3 层进行重构分析, 其时频谱分别如图 1 和 2 所示。由图可见, 与原始 EWT 相比, MEWT 能较为准确地分解仿真信号, 对噪声鲁棒性较强。

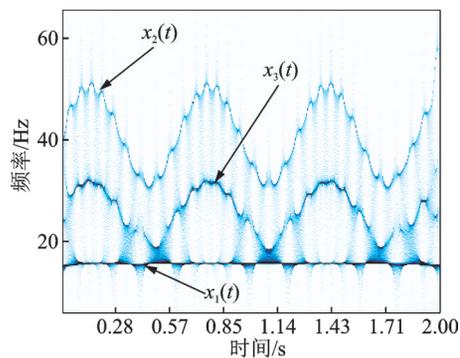


图1 MEWT时频图

Fig. 1 MEWT time-frequency diagram

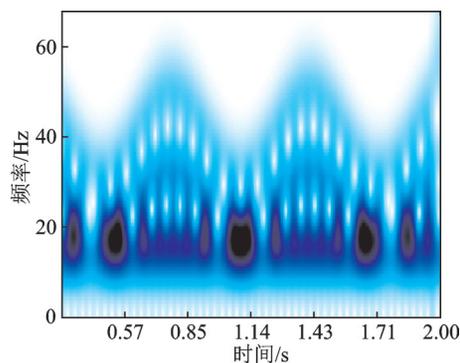


图2 原始EWT时频图

Fig. 2 Raw EWT time-frequency diagram

1.4 综合评价指标

文献[12]提出一种加权评价指标, 有效改进了VMD的虚假模态问题, 本文将引入MEWT中, 其表达式如下:

$$P = \eta K_r + \varphi r_{xy} + \xi e_{xy} \quad (15)$$

$$\eta + \varphi + \xi = 1 \quad (16)$$

式中 φ, η, ξ 为比例系数, $0 < \varphi, \eta, \xi < 1$ 。 K_r 表示峭度, 其值越大, 表明信号周期性冲击成分比重越大; r_{xy} 为相关系数, 其值越大, 表明各模态与原始信号相关程度越大; e_{xy} 为能量比, 可剔除MEWT因能量泄漏引入的附加成分。考虑到轴承振动信号的特性,

经反复试验并结合文献[12]和粒子群优化算法, 最终取各指标为相同权值, 并选择 P 值最大的前 4 个模态分量进行重构。

2 IFractalNet

2.1 FractalNet简介

CNN作为深度学习的重要模型, 主要由卷积层、池化层、全连接层和分类层等组成, 一般架构如图3所示。

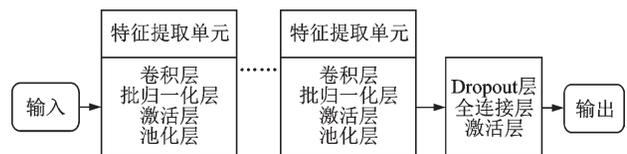


图3 CNN结构

Fig. 3 The structure of CNN

CNN随层数加深, 梯度消失现象明显, 进而造成识别率降低, 且其最优结构难以确定。FractalNet^[13]不依赖残差框架, 通过选择合适的子路径集合提升模型表现, 较好地解决了CNN存在的问题, 结构如图4所示。

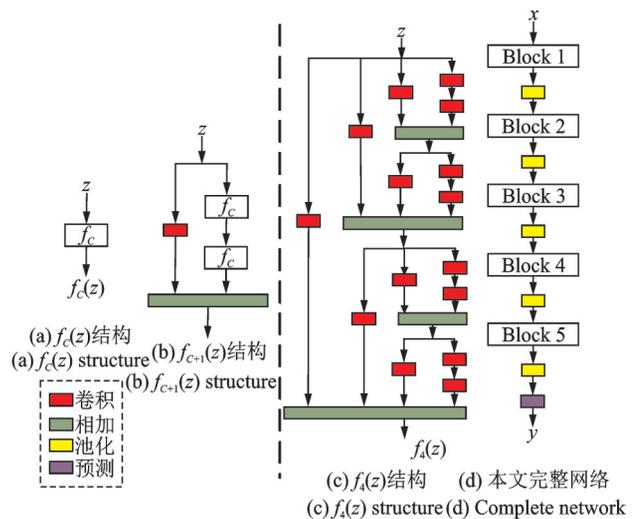


图4 分形网络结构

Fig. 4 The FractalNet structure

其中, 红色卷积层 Convolution 为基础层; 绿色 Join 层为相加操作。 $f_c(z)$ 中, C 为列数, z 为输入, $C=1$ 表示一个基础层。 $f_{c+1}(z)$ 如图 4(b) 所示, 在右边叠加两个 $f_c(z)$, 左边连接一个基础层。以此类推, 当 C 取 4 时, $f_n(z)$ 可作为一个 block 块。图 4(d) 所示为网络连接 5 个 block, block 之间以池化层连接, 最后是预测层。令 block 个数为 B , 每个 block 列数为 C , 则 FractalNet 深度为 $B \times 2^{C-1}$ 。 FractalNet 采取 drop-path 正则化, 如图 5 所示, 可有效防止网络过

拟合。网络训练时,mini-batch之间交叉使用局部采样和全局采样,图5(a)和(c)为局部采样方法,对join层的输入进行 dropout操作,要求至少保证要有一个输入,图5(b)和(d)为全局采样方法,对于整个网络来说,只选择一条路径,且限制为某个单独列,FractalNet详细训练算法见文献[13]。

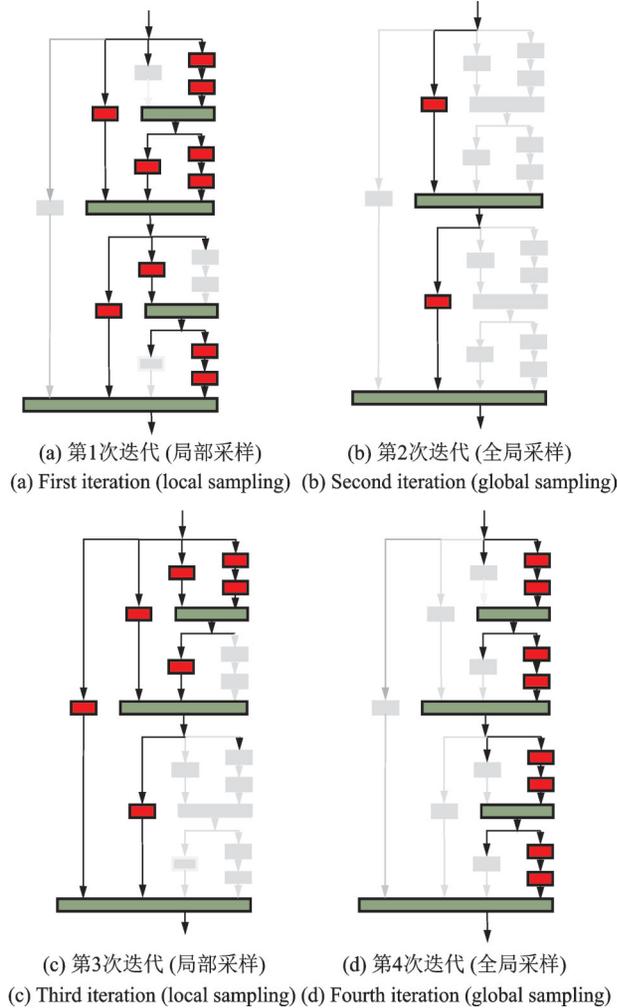


图5 Drop-path正则化方法

Fig. 5 The drop-path regularization method

2.2 改进损失函数

为有效缓解因轴承故障样本不平衡造成故障识别率低的问题,鉴于文献[14],本文改进原始FractalNet的损失函数,对样本较多的故障类别赋以较小权重,对样本较少的类型赋以较大的权值,如下式所示:

$$W_s = -\frac{1}{Q} \sum_{q=1}^Q \sum_{c=1}^C v_c l\{y^q = c\} \lg P_c^{(q)} \quad (17)$$

$$v_c = \frac{\max\{n_c\}_{c=1}^C}{n_c} \quad (18)$$

$$n_c = \sum_{q=1}^Q l\{y^q = c\} \quad (19)$$

$$P_c^{(q)} = \frac{\exp[(\mathbf{w}_c^{K,L})^T \mathbf{x}^{(q),L-1}]}{\sum_{c=1}^C \exp[(\mathbf{w}_c^{K,L})^T \mathbf{x}^{(q),L-1}]} \quad (20)$$

同时加入正则惩罚项,如下式所示

$$R(W) = \sum_K \sum_l W_{K,l}^2 \quad (21)$$

将正则项与交叉熵函数合并的损失函数如下式所示

$$L_s = W_s + \lambda R(W) \quad (22)$$

式(17)-(22)中 n_c 为第 c 类故障样本个数, v_c 为第 c 类故障样本相对于其他类样本的不平衡程度, C 和 Q 分别为总故障类别数和样本总数, $P_c^{(q)}$ 为样本输出值, $\mathbf{w}_c^{K,L}$ 为连接权值, y^q 为样本 y 在 q 类下的类标, L 为网络层数, λ 为正则项系数, $R(W)$ 为偏差权重矩阵, $W_{K,l}$ 为非卷积层之间的权值矩阵。

文献[15]利用 Fisher 惩罚项,使深层自编码网络学习到的隐层特征对振动信号的结构变化具有可区分性。本文将 Fisher 惩罚项引入 FractalNet。Fisher 准则表达式如下

$$J(\mathbf{w}) = \frac{J_B}{J_W} = \frac{\mathbf{w}^T \mathbf{S}_B \mathbf{w}}{\mathbf{w}^T \mathbf{S}_W \mathbf{w}} \quad (23)$$

式中 J_B 为类间离散度, J_W 为类内离散度, \mathbf{S}_B 为类间离散度矩阵, \mathbf{S}_W 为类内离散度矩阵, \mathbf{w} 为投影方向。本文将 FractalNet 看作是从振动信号到相似矩阵的一种非线性映射关系,对于轴承振动信号样本集 $X = \{x_1, x_2, \dots, x_N\}$, 模型输出如下

$$V(x_i) = \text{FractalNet}(x_i) \quad (24)$$

式中 $\text{FractalNet}(x_i)$ 为 FractalNet 的前向计算过程, $V(x_i)$ 为网络对样本集 X 中第 i 个样本 x_i 经非线性映射输出的相似向量。 J_W 和 J_B 计算如下:

$$J_W = \frac{1}{N} \sum_{j=1}^k \sum_{x_i \in y_j} [V(x_i) - \bar{V}_j] [V(x_i) - \bar{V}_j]^T \quad (25)$$

$$J_B = \frac{1}{N} \sum_{i=1}^k N_i (\bar{V}_i - \bar{V})(\bar{V}_i - \bar{V})^T \quad (26)$$

式中 \bar{V}_j 为第 j 类故障样本相似矩阵的平均值, \bar{V} 为所有样本相似矩阵的平均值。

$$\bar{V}_j = \frac{1}{N_j} \sum_{x_i \in y_j} V(x_i) \quad (27)$$

$$\bar{V} = \frac{1}{N} \sum_{i=1}^N V(x_i) \quad (28)$$

综上,本文最终的损失函数为

$$L = W_s + \lambda R(W) + J_W - \gamma J_B \quad (29)$$

式中 γ 为两种离散度的权重系数。

2.3 改进激活函数

CNN 中最常用的 ReLU 激活函数虽然计算效率较高,但很容易产生“神经元死亡”现象,造成网络性能下降; PReLU, LReLU 等激活函数一定程度改进了 ReLU 的缺陷,但在零点处不光滑且效率不高。

高斯误差线性单元(Gaussian Error Linear Unit, GELU)通过对网络的输入进行随机正则化。与ReLU不同,GELU依据输入的幅值大小进行加权,在语音识别任务上效果明显优于ReLU,GELU近似公式如下

$$\text{GELU}(x) = 0.5x \left\{ 1 + \tanh \left[\sqrt{2/\pi} (x + 0.044715x^3) \right] \right\} \quad (30)$$

其在正值区间内是非线性的,并且在所有点处都有曲率,而ReLU在正值区间是线性的,因此缺乏曲率;GELU在正值区间的变化更为显著,在反向传播时可以更有效地更新梯度,在负值区域,GELU函数的值普遍更接近 x 轴,因此具有更佳的双边抑制效果,可更好地缓解深层网络的梯度消失或梯度爆炸现象。因此本文将引入FractalNet。综上,本文整体识别算法步骤如下:

- (1)采集不同故障的滚动轴承振动信号;
- (2)进行样本划分,并对每个样本进行MEWT分解,利用加权评价指标选择故障特征信息明显的 $imfs$ 分量并重构;
- (3)将训练样本输入IFractalNet进行训练;
- (4)通过测试样本验证基于MEWT和IFractalNet模型的识别性能。图6为识别流程。

3 实验验证

3.1 实验数据描述

为验证提出算法的可行性和有效性,进行实际滚动轴承故障识别实验。本次实验所用的测试平台由Spectra Quest公司设计生产,该平台可以开展各类滚动轴承或滑动轴承的故障诊断及加速退化实验,如图7所示。通过杭州亿恒科技有限公司的MI6008型数据采集仪、美国PCB公司的352C33型ICP加速度传感器和笔记本电脑采集滚动轴承的振动信号。测试平台由交流感应电动机、电机速度控制器、测试轴承、加载系统等组成,该平台是为在不同工况(即不同负载和转速)下对轴承进行故障识别试验而设计的。负载由加载系统产生,应用于被测轴承壳体,转速由交流感应电动机的速度控制器设定和保持。测试轴承为LDK UER204滚动轴承。

为了采集被测轴承的振动信号,两个ICP 352C33型加速度计位于被测轴承外壳上的 90° 位置,即一个安装在水平轴上,另一个安装在垂直轴上。采样频率设置为25.6 kHz,每次采样总共记录40000个数据点。使用电火花技术在滚动轴承内圈、外圈和滚动体上加工故障直径为0.16和0.3 mm的环槽,共设计了7种不同的轴承故障工况,如表1所示。

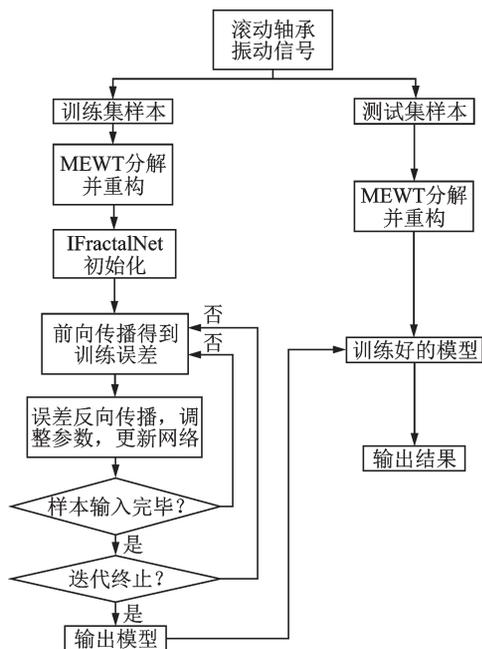


图6 故障识别流程图

Fig. 6 Fault identification flow chart

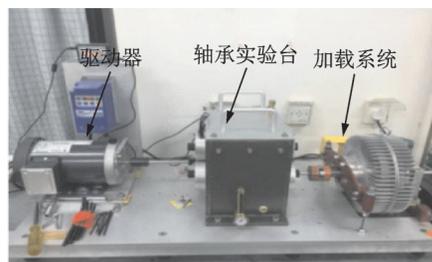


图7 轴承实验台

Fig. 7 The rolling bearing experimental setup

表1 7种轴承故障工况

Tab. 1 Seven bearing fault working conditions

故障位置	代号	转速/Hz	负载/kN	故障尺寸/mm
正常	a	30	12	—
内圈	b	37.5	11	0.16
内圈	c	40	10	0.30
外圈	d	30	12	0.16
外圈	e	37.5	11	0.30
滚动体+内圈	f	40	10	0.16
滚动体+外圈	g	37.5	11	0.30

训练IFractalNet需要大量样本数据,因此本文采用文献[16]提出的方法对振动信号进行有重叠样本分割,从而实现样本扩充。最后得到每种工况下8000个样本,随机选取70%作为训练样本,剩余作为测试样本。图8为7种工况的时域图和频域图。

由时域图可知,复合故障冲击成分不明显,部分冲击淹没在噪声中,振动情况较为复杂;由频域图可知对于同种故障类型但不同工况的故障,从频谱上难以区分。

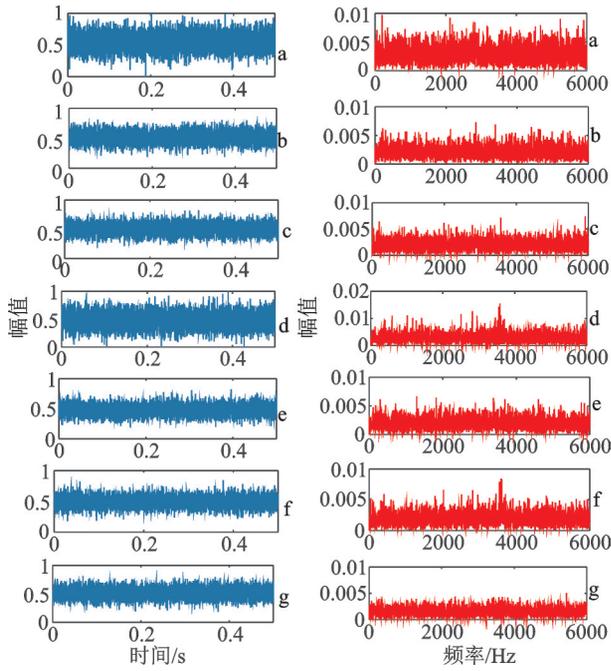


图 8 轴承 7 种工况时域图和频域图

Fig. 8 Time domain and frequency domain diagrams of bearing under 7 working conditions

3.2 轴承实际振动信号分解

以转速 30 Hz、负载 12 kN 工况下轴承外圈故障振动信号为例,分别采用原始 EWT 和 MEWT 对其进行分解,结果如图 9 和 10 所示,原始 EWT 模态混叠严重,干扰较多;MEWT 分解模态数少于原始 EWT,根据加权评价指标,对重构信号进行时频分析,如图 11 和 12 所示。由下式计算求得轴承外圈故障特征频率约为 120 Hz。

$$f_o = \frac{1}{2} f_r (1 - \frac{d}{D} \cos \alpha) Z \quad (31)$$

式中 d 为滚子直径, D 为节圆直径, α 为接触角, Z 为滚子数, f_r 为转频 30 Hz,从 MEWT 时频谱中可以看出比较清晰地看出故障外圈故障频率以及倍频,验证了 MEWT 的有效性。

3.3 故障识别结果与分析

采用深度置信网络 (deep belief network, DBN)、深层稀疏自动编码器 (deep sparse auto-encoder, DSAE)、原始 EWT+IFractalNet, MEWT+CNN 和 MEWT+原始 FractalNet 等方法进行对比分析。其中, DBN 和 DSAE 有两种输入:一种为原始振动信号,一种为经 MEWT 分解并重构后的振动信号(2000 维),各方法的参数如下:

方法 1(本文方法):MEWT+IFractalNet, IFractalNet 结构如图 4(d) 所示,卷积核宽度为 3,高度为 1;输入特征图数量为 32;池化层宽度为 2;卷积核移动步长为 1;为避免尺寸的变化,在输入矩阵的边

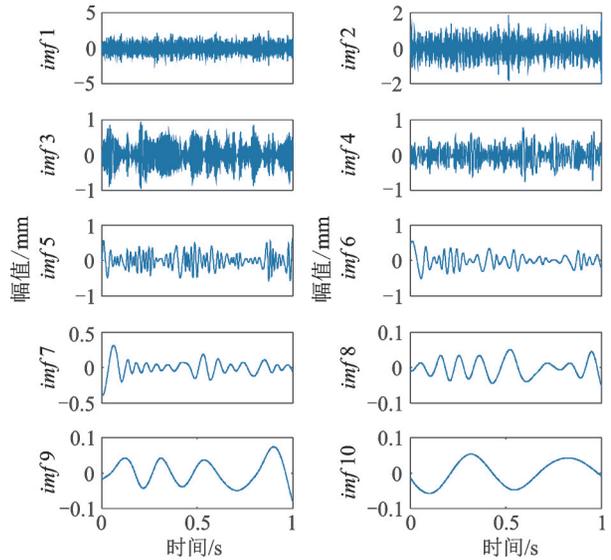


图 9 原始 EWT 分解结果

Fig. 9 Raw EWT decomposition results

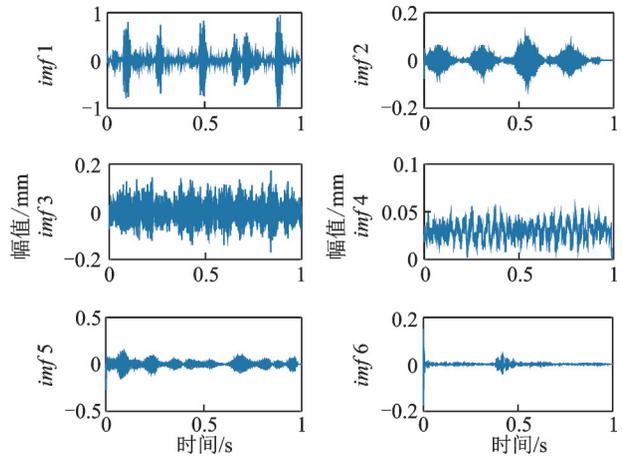


图 10 MEWT 分解结果

Fig. 10 MEWT decomposition results

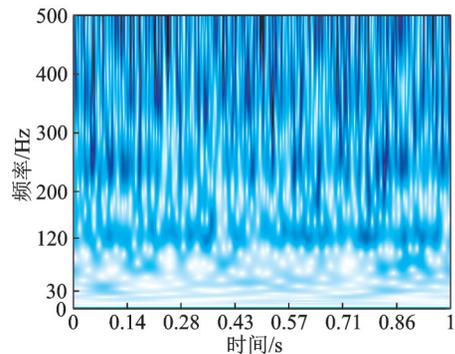


图 11 原始 EWT 时频图

Fig. 11 Raw EWT time-frequency diagram

界上加入全 0 填充,卷积层与池化层之间都存在批归一化层与激活层。

方法 2(DBN):DBN 结构为 2000-1000-500-200-50-7,每个限制玻尔兹曼机的学习率、动量因子分别为 0.04,0.1。

方法 3(MEWT+DBN):DBN 结构同方法 2。

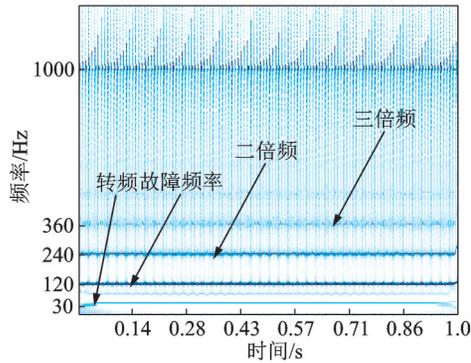


图12 MEWT时频图

Fig. 12 MEWT time-frequency diagram

方法4(DSAE): DSAE的结构为2000-1000-500-200-50-7,每个稀疏自编码器的学习率为0.14,动量因子为0.1,迭代次数为200。

方法5(MEWT+DSAE): DSAE结构同方法4。

方法6(原始EWT+IFractalNet): IFractalNet结构同方法1。

方法7(MEWT+CNN): CNN结构同文献[6]。

方法8(MEWT+原始FractalNet): FractalNet同方法1,但其损失函数和激活函数同文献[13]。

表2列出了测试阶段的平均识别准确率与标准差,图13列出了在每次试验中采用不同方法测试的详细识别结果。

表2 不同方法的识别结果

Tab. 2 Identification results of different methods

方法	测试集平均识别准确率/ %±标准差
方法1	99.78 ± 0.08
方法2	81.29 ± 2.57
方法3	90.11 ± 1.07
方法4	82.54 ± 2.19
方法5	91.75 ± 1.13
方法6	94.43 ± 0.81
方法7	93.67 ± 0.89
方法8	96.87 ± 0.28

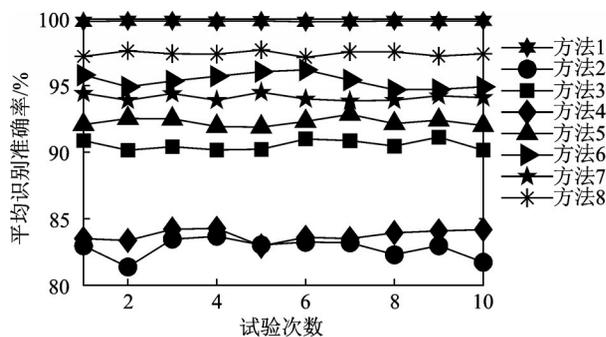


图13 不同方法的10次测试结果

Fig. 13 Testing results of different methods for 10 trials

由表2可知,与其他方法相比,本文方法具有更高的故障识别准确率和更小的标准差,平均识别准确率达99.78%,标准差仅为0.08。方法2与方法3、方法4与方法5、方法1与方法6的对比结果表明MEWT的分解降噪效果优于原始EWT;方法1与方法7、方法8的对比结果表明,IFractalNet的特征提取和识别结果优于CNN和原始FractalNet。本文提出方法利用MEWT自适应划分滚动轴承振动信号频谱的边界,从而确定分解模态然后利用加权评价指标进行信号重建,并改进FractalNet的损失函数和激活函数,相较于其他方法具有更高的故障识别能力。图14给出了本文提出方法的第1次测试结果的混淆矩阵,可以看出,复合故障工况f和g的识别准确率较低。

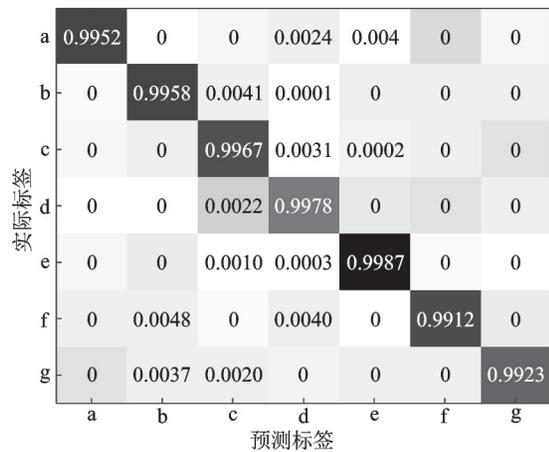


图14 混淆矩阵

Fig. 14 Confusion matrix

实际情况中,正常工况的样本比例要大于故障工况样本比例,进一步研究本文提出方法在不平衡样本比例下的故障识别性能。共设置5组不同比例的不平衡样本,正常工况和各故障工况的训练样本数量比例分别设置为8000:8000,8000:7000,8000:6000,8000:5000和8000:4000,共进行10次实验,取平均结果,同时与方法6、方法7和方法8进行对比分析,识别准确率如表3所示。

由表3可知,在不平衡训练样本情况下,本文方法(方法1)的故障识别效果仍然优于其他几种方

表3 不平衡样本下4种方法的识别准确率/%

Tab. 3 Identification accuracy of 4 methods under unbalanced samples/%

组别	本文方法	方法6	方法7	方法8
组1	99.78	94.43	93.67	96.87
组2	98.12	93.36	90.34	94.10
组3	97.12	92.87	87.74	91.78
组4	96.26	91.78	85.98	89.39
组5	95.14	91.12	80.09	87.98

法;在第 5 组中,即当不平衡比例达 8000:4000 时,本文方法的平均识别准确率达到 95.14%。综上,4 种方法的识别准确率均随不平衡比例的增大整体呈现下降趋势,但本文方法在面对不平衡训练样本时表现更加优异。

以组 5 为例,计算了本文方法和方法 8 基于不平衡样本的准确率(P)、召回率(R)和 F_1 值,如下式所示

$$\begin{aligned}
 P &= \frac{T_p}{T_p + F_p} \times 100\%, \\
 R &= \frac{T_p}{T_p + F_N} \times 100\%, \\
 F_1 &= \frac{2PR}{P + R} \quad (32)
 \end{aligned}$$

式中 T_p 为正样本中被模型判断为正的个数, F_p 为负样本中被模型判断为正的个数, F_N 为正样本中被模型判断为负的个数, F_1 值范围在 $[0, 1]$ 之间, 0 代表最差, 1 代表最好。表 4 列出了组 5 中两种方法的计算结果, 可知, 组 5 中本文方法的 P, R 和 F_1 指标值均较高, 类似的结果在其他组中也有明显体现。对比结果进一步验证了本文方法在面对不平衡样本时故障识别的优越性和有效性。

表 4 组 5 两种方法的精确率、召回率和 F_1 值

Tab. 4 The values of P, R and F_1 under two methods in group 5

工况	本文方法			方法 8		
	$P/\%$	$R/\%$	F_1	$P/\%$	$R/\%$	F_1
a	95.84	95.15	0.94	90.41	77.82	0.86
b	95.34	95.54	0.95	89.24	80.79	0.85
c	95.41	95.74	0.95	89.19	78.58	0.87
d	96.15	94.58	0.96	90.32	80.89	0.86
e	95.57	94.41	0.95	90.58	99.12	0.84
f	94.28	93.83	0.95	88.67	70.87	0.83
g	94.36	91.16	0.94	88.11	76.24	0.83

作为深层网络传递信息的“门”, 激活函数对于深层网络至关重要。本文研究 ReLU, Swish 和 GELU 函数对 IFractalNet 识别性能的影响, 图 15 为不同激活函数下 IFractalNet 的训练精度随迭代次数的变化曲线, 可见 8000 次迭代后, GELU 函数的识别准确率比 ReLU 的训练精度提高了 7.9%, 比 Swish 提高了 5.8%, 表明 GELU 函数具有较好的收敛精度。

4 结 论

本文提出一种基于 MEWT 和 IFractalNet 的滚动轴承故障识别方法, 主要结论如下:

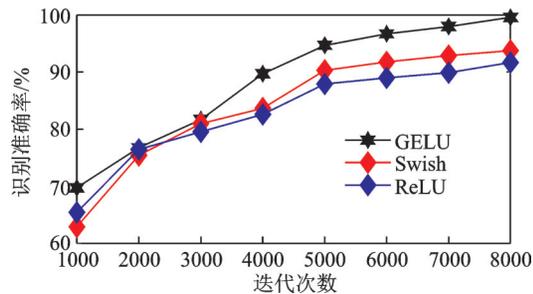


图 15 不同激活函数的收敛精度比较

Fig. 15 Comparison of convergence accuracy for different activation functions

(1) 提出一种形态学 EWT 分解方法, 利用形态滤波提取振动信号频谱中具有显著特征的局部极大值作为频谱划分边界, 自适应地分割滚动轴承振动信号的频谱, 并利用辅助白噪声优化 EWT, 实现更精确的 EWT 自适应模态分解, 仿真信号和实际信号实验表明 MEWT 的分解降噪效果优于原始 EWT, 对噪声的鲁棒性更强。

(2) 针对 CNN 层数越深, 梯度消失现象越明显, 进而造成识别率越低的缺陷, 将 FractalNet 引入滚动轴承故障识别领域, 并针对不平衡数据集改进 FractalNet 的损失函数, 对样本较多的故障类别赋以较小权重, 对样本较少的故障类型赋以较大的权值; 将 Fisher 惩罚项引入 FractalNet 的损失函数, 使网络学习到的隐层特征对振动信号的结构变化具有可区分性; 为缓解 ReLU 函数造成的“神经元死亡”现象, 将 GELU 作为 IFractalNet 的激活函数, 实验表明 IFractalNet 的自动特征提取与故障识别能力均优于 CNN 和原始 FractalNet, 在不平衡训练样本集上也取得较好的效果。

参考文献:

[1] 王奉涛, 邓刚, 王洪涛. 基于 EMD 和 SSAE 的滚动轴承故障诊断方法[J]. 振动工程学报, 2019, 32(2): 368-376.
Wang Fengtao, Deng Gang, Wang Hongtao, et al. A rolling bearing fault diagnosis method based on EMD and SSAE[J]. Journal of Vibration Engineering, 2019, 32(2): 368-376.

[2] Pan H Y, Yang Y, Li X, et al. Symplectic geometry mode decomposition and its application to rotating machinery compound fault diagnosis[J]. Mechanical Systems and Signal Processing, 2019, 114: 189-211.

[3] Gilles J. Empirical wavelet transform[J]. IEEE Transactions on Signal Processing, 2013, 61(16): 3999-4010.

[4] Jurgen S. Deep learning in neural networks: An overview[J]. Neural Networks, 2015, 61(1): 85-117.

[5] Chen Z Q, Li C, Sanchez R V. Gearbox fault identifica-

- tion and classification with convolutional neural networks[J]. Shock and Vibration, 2015, (2):1-10.
- [6] Wang L H, Zhao X P, Wu J X, et al. Motor fault diagnosis based on short-time Fourier transform and convolutional neural network[J]. Chinese Journal of Mechanical Engineering, 2017, 30(6): 1357-1368.
- [7] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016: 770-787.
- [8] Zhao M, Kang M, Tang B, et al. Deep residual networks with dynamically weighted wavelet coefficients for fault diagnosis of planetary gearboxes [J]. IEEE Transactions on Industrial Electronics, 2018, 65(5): 4290-4300.
- [9] Yeh Jia-Rong, Shieh Jiann-Shing, Huang Norden E. Complementary ensemble empirical mode decomposition: A novel noise enhanced data analysis method[J]. Advances in Adaptive Data Analysis, 2011, 2(2): 135-156.
- [10] 姜海旭, 张 科, 王靖宇, 等. 基于形态变分模态分解和JRD的航天器异常状态识别[J]. 西北工业大学学报, 2018, 36(1): 20-27.
- Jiang Haixu, Zhang Ke, Wang Jingyu, et al. Spacecraft anomaly recognition based on morphological variational mode decomposition and JRD[J]. Journal of Northwestern Polytechnical University, 2018, 36(1): 20-27.
- [11] 刘 姝. 数学形态学在信号处理方面的应用研究[D]. 大连: 大连理工大学, 2006.
- Liu Shu. Applying the mathematical morphology in signal processing[D]. Dalian: Dalian University of Technology, 2006.
- [12] 何洋洋, 吕跃刚, 刘俊承. 基于VMD与粒子滤波的滚动轴承故障诊断[J]. 可再生能源, 2019, 37(1): 126-131.
- He Yangyang, Lü Yuegang, Liu Juncheng. Fault diagnosis of rolling bearing based on VMD and particle filter [J]. Renewable Energy Resources, 2019, 37(1): 126-131.
- [13] Larsson G, Maire M, Shakhnarovich G. FractalNet: Ultra-deep neural networks without residuals[J]. 2016, arXiv:1605.07648.
- [14] 冯新扬, 张巧荣, 李庆勇. 基于改进型深度网络数据融合的滚动轴承故障识别[J]. 重庆大学学报, 2019, 42(2): 52-62.
- Feng Xinyang, Zhang Qiaorong, Li Qingyong. Fault recognition of rolling bearing based on improved deep networks with data fusion in unbalanced data sets [J]. Journal of Chongqing University, 2019, 42(2): 52-62.
- [15] 陈志刚, 杜小磊, 王衍学, 等. 改进集成深层自编码器在轴承故障诊断中的应用[J]. 控制与决策, 2021, 36(1): 135-142.
- Chen Zhigang, Du Xiaolei, Wang Yanxue, et al. Application of improved ensemble deep auto-encoder in bearing fault diagnosis[J]. Control and Decision, 2021, 36(1): 135-142.
- [16] Qu J X, Zhang Z S, Gong T. A novel intelligent method for mechanical fault diagnosis based on dual-tree complex wavelet packet transform and multiple classifier fusion[J]. Neurocomputing, 2016, 171: 837-853.

Application of morphological empirical wavelet transform and IFractalNet in bearing fault identification

DU Xiao-lei^{1,2}, CHEN Zhi-gang^{1,2}, WANG Yan-xue^{1,3}, ZHANG Nan¹

(1.School of Mechanical-Electronic and Vehicle Engineering, Beijing University of Civil Engineering and Architecture, Beijing 100044, China; 2.Beijing Engineering Research Center of Monitoring for Construction Safety, Beijing 100044, China; 3.Beijing Key Laboratory of Performance Guarantee on Urban Rail Transit Vehicles, Beijing University of Civil Engineering and Architecture, Beijing 100044, China)

Abstract: Considering that the traditional rolling bearing fault identification methods heavily rely on expert experience and are difficult in fault feature extraction and selection, a method based on morphological empirical wavelet transform (MEWT) and improved FractalNet (IFractalNet) is proposed. The raw vibration signals of rolling bearings are adaptively decomposed into several intrinsic modal components by MEWT. The components with obvious fault characteristics are selected using the comprehensive evaluation index and then reconstructed. Considering that the defects of the raw FractalNet, the loss function, activation function and optimization method are improved. The reconstructed vibration signals are fed into IFractalNet for automatic feature extraction and fault identification. The experimental results indicate that the proposed method avoids the complex manual feature extraction process and can effectively identify the various fault types and multiple fault severities of rolling bearings, which shows obvious superiorities in generalization ability, feature extraction ability, and fault identification ability.

Key words: fault identification; rolling bearing; morphological empirical wavelet transform; IFractalNet

作者简介: 杜小磊(1993-),男,硕士研究生。电话: 13260417530;E-mail:13260417530@163.com

通讯作者: 陈志刚(1979-),男,副教授。电话: 13521909643;E-mail:ganzhi22@163.com