

# 增强辛几何模态分解和自组织自编码卷积网络的电机轴承工况识别

陈志刚<sup>1,2</sup>, 杜小磊<sup>3</sup>, 王衍学<sup>1,4</sup>

(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.电子科技大学机械与电气工程学院, 四川 成都 611731;

4.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:** 针对电机轴承振动信号特征提取与工况识别困难的问题, 提出一种基于增强辛几何模态分解(ESGMD)和自组织自编码卷积网络(SOAECN)的电机轴承工况识别方法。在辛几何模态分解(SGMD)的基础上将电机轴承振动信号自适应分解为初始辛几何模态分量(ISGMCs), 并利用改进凝聚聚类算法对 ISGMCs 重新组合得到聚类辛几何模态分量(CSGMCs); 提出一种综合评价指标, 利用此指标筛选能反映振动信号特征的 CSGMCs 分量并重构; 结合卷积神经网络和小波自编码器, 构造自编码卷积网络(AECN), 并在 AECN 基础上改进其损失函数且引入自组织策略, 进而构造 SOAECN; 将重构后的振动信号输入 SOAECN 进行自动特征提取与工况识别。实验结果表明: ESGMD-SOAECN 方法的工况识别率达到了 98.76%, 自动特征提取能力和工况识别能力优于深度稀疏自动编码器、深度降噪自动编码器和深度信念网络等深度学习方法, 可为电机轴承自动工况识别提供参考。

**关键词:** 故障诊断; 轴承; 工况识别; 辛几何模态分解; 自组织自编码卷积网络; 改进凝聚聚类

**中图分类号:** TH165<sup>+</sup>.3; TH133.3 **文献标志码:** A **文章编号:** 1004-4523(2022)04-0958-11

**DOI:** 10.16385/j.cnki.issn.1004-4523.2022.04.020

## 引言

滚动轴承是电机的重要部件, 较容易受到损伤而出现故障, 进而影响整个电机的性能<sup>[1]</sup>。目前, 基于振动信号的电机轴承工况识别研究最为广泛, 一方面, 由于电机轴承振动信号传递路径较复杂, 信号呈现出明显的非线性和非平稳性; 另一方面, 振动信号易受环境噪声干扰, 信噪比较低。

深层自编码器(Deep Auto-Encoder, DAE)<sup>[2]</sup>能自动从信号中学习有价值的特征, 克服了“人工特征提取-特征选择-工况识别”方法的缺陷<sup>[3]</sup>, 在电机轴承工况识别领域取得了一定突破。Shao 等<sup>[4]</sup>结合多种 DAE, 对电机轴承多种工况进行了有效识别; Shao 等<sup>[5]</sup>提出集成 DAE, 采用多种不同的激活函数, 使电机轴承工况识别结果更稳定。虽然上述基于 DAE 的电机轴承工况识别研究取得了一定成果, 但仍存在如下缺陷: (1) DAE 训练过程中结构固定不变, 仅更新网络权值, 难以有效处理非线性和非平稳性振动信号<sup>[6]</sup>; (2) DAE 为全连接网络, 训练参数

众多, 训练时间较长<sup>[7]</sup>; (3) 众多研究<sup>[8-10]</sup>表明, 若直接将含噪信号输入 DAE, 噪声的存在不仅会降低工况识别准确率, 还会降低 DAE 的收敛速度。在信号降噪方法中, 小波降噪缺乏自适应性; 经验模态分解及其变体<sup>[11-13]</sup>等降噪方法存在模态混叠现象; 变分模态分解<sup>[14]</sup>和经验小波变换<sup>[15]</sup>的分解模态个数难以确定; 辛几何模态分解(Symplectic Geometry Mode Decomposition, SGMD)<sup>[16]</sup>能有效保持时间序列的本质特征, 适合电机轴承振动信号的分析。程正阳等<sup>[17]</sup>将 SGMD 应用于齿轮工况识别分析; 郑直等<sup>[18]</sup>利用 SGMD 分解液压泵振动信号, 并利用广义形态分形维数对泵的工况进行识别。尽管 SGMD 取得一定成效, 但辛几何分量选取困难。

本文在 SGMD 基础上采用改进凝聚聚类算法对初始辛几何模态分量进行有效重组, 并提出新的综合评价指标筛选有效的模态分量进行重构, 最后结合 SOAECN 进行电机轴承工况识别, 试验验证了 ESGMD-SOAECN 方法的可行性和有效性。

**收稿日期:** 2020-11-10; **修订日期:** 2021-03-12

**基金项目:** 国家自然科学基金资助项目(51875032); 北京建筑大学市属高校基本科研业务费专项资金资助项目(X20061)。

## 1 增强辛几何模态分解

### 1.1 辛几何模态分解

设信号  $x = x_1, x_2, \dots, x_n$ , 根据 Takens 嵌入定理<sup>[19]</sup>, 将  $x$  投影到轨迹矩阵  $X$ , 如下式所示:

$$X = \begin{bmatrix} x_1 & x_{1+\tau} & \cdots & x_{1+(d-1)\tau} \\ \vdots & \vdots & & \vdots \\ x_m & x_{m+\tau} & \cdots & x_{m+(d-1)\tau} \end{bmatrix} \quad (1)$$

式中  $d$  为嵌入维度;  $m = n - (d-1)\tau$ ;  $\tau$  为延迟时间,  $\tau$  的确定采用 C-C 算法<sup>[20]</sup>。对  $X$  进行自相关分析, 得协方差对称矩阵  $A$ :

$$A = X^T X \quad (2)$$

然后构造哈密顿矩阵  $M$ :

$$M = \begin{bmatrix} A & 0 \\ 0 & -A^T \end{bmatrix} \quad (3)$$

则  $N = M^2$  也为哈密顿矩阵, 进而构造辛正交矩阵  $Q$ :

$$Q^T N Q = \begin{bmatrix} B & R \\ 0 & B^T \end{bmatrix} \quad (4)$$

式中  $R$  为矩阵变换后的子矩阵;  $B$  为上三角矩阵, 其特征值分别为  $\lambda_1, \lambda_2, \lambda_3, \dots, \lambda_d$ , 则  $A$  的特征值为:

$$\sigma_i = \sqrt{\lambda_i} \quad (i = 1, 2, \dots, d) \quad (5)$$

$$\sigma_1 > \sigma_2 > \dots > \sigma_d \quad (6)$$

式中  $\sigma_i$  的分布为  $A$  的辛几何谱,  $Q_i (i = 1, 2, \dots, d)$  为  $\sigma_i$  的特征向量, 则各分量矩阵的重构步骤如下:

首先, 计算变换系数矩阵:

$$S_i = Q_i^T X^T \quad (7)$$

然后, 对  $S_i$  进行变换, 得到单分量成分  $Z_i$ :

$$Z_i = Q_i S_i \quad (8)$$

式中  $i = 1, 2, \dots, d$ 。则初始单分量轨迹矩阵  $Z$  如下式所示:

$$Z = Z_1 + Z_2 + \dots + Z_d \quad (9)$$

式中  $Z \in \mathbb{R}^{m \times d}$ 。定义  $Z_i$  中元素为  $z_{ij}, 1 \leq i \leq d, 1 \leq j \leq m$ , 且  $d^* = \min(m, d), m^* = \max(m, d), n = m + (d-1)\tau$ , 令:

$$z_{ij}^* = \begin{cases} z_{ij}, & m < d \\ z_{ji}, & m \geq d \end{cases} \quad (10)$$

则对角平均转换矩阵可由下式得到:

$$y_k = \begin{cases} \frac{1}{k} \sum_{p=1}^k z_{p, k-p+1}^*, & 1 \leq k \leq d^* \\ \frac{1}{d^*} \sum_{p=1}^{d^*} z_{p, k-p+1}^*, & d^* < k \leq m^* \\ \frac{1}{n-k+1} \sum_{p=k-m^*+1}^{n-m^*+1} z_{p, k-p+1}^*, & m^* < k \leq n \end{cases} \quad (11)$$

通过对角平均可将矩阵  $Z$  变换为  $d \times n$  维的矩

阵  $Y$ , 从而将信号  $x$  分解为  $d$  个具有不同趋势项和不同频带的初始辛几何模态分量 (Initial Symplectic Geometric Mode Components, ISGMCs):

$$Y = Y_1 + Y_2 + \dots + Y_d \quad (12)$$

### 1.2 改进凝聚聚类算法

在聚类算法中, 层次聚类和凝聚聚类会增加算法的复杂度, 因此本文利用改进凝聚聚类算法减小计算量。用改进凝聚聚类对  $Y_1, Y_2, \dots, Y_d$  进行分析与重组, 将每个  $Y_i$  视作元素  $t_i = (Y_i)$ , 记  $T = (t_1, t_2, \dots, t_d)$ , 则集合  $T$  中  $t_i$  和  $t_j$  的综合距离计算如下:

$$d'(t_i, t_j) = \frac{\sqrt{\sum_{k=1}^d d_k^2(t_i, t_j)}}{d} \quad (13)$$

其中,  $d_k$  可通过最短距离法、最长距离法或平均距离法计算得到。则  $t_i$  和  $t_j$  的综合相似度  $s$  计算如下:

$$s(t_i, t_j) = 1 - d'(t_i, t_j) \quad (14)$$

本文采用结构体数组记录数据的初始位置及相似度  $s$ , 相似度阈值根据文献[21]和经反复实验取为 0.85, 改进凝聚聚类算法步骤如下:

(1) 计算  $T$  中任意 2 个元素  $t_i$  和  $t_j$  的相似度  $s(t_i, t_j)$ , 存储在数组  $S$  中。

(2) 对数组  $S$  从大到小进行排序。

(3) 判断数组  $S$  中的 2 个元素是否合并为一类, 若否, 则合为一类; 若 1 个元素已被合并到某一类, 则另一元素也合并到此类; 若 2 个元素被合并到两个不同的类, 则两类合并为一类。

(4) 取  $S$  中下一个元素, 重复步骤 (3), 直到  $S$  中所有元素处理完毕。最终得到:

$$Y = Y_1^* + Y_2^* + \dots + Y_q^* \quad (15)$$

式中  $q$  为聚类组数;  $Y_i^*$  为聚类辛几何模态分量 (Clustering Symplectic Geometric Modal Component, CSGMC)。

### 1.3 综合评价指标

峭度对冲击信号敏感, 但忽略了轴承振动信号的循环平稳性。为更有效地保留信号的故障冲击信息, 提出一种综合评价指标  $Q$  用于 CSGMCs 有效分量的选取,  $Q$  的表达式如下:

$$Q = \eta_1 K_w + \eta_2 K_c \quad (16)$$

式中  $0 < \eta_1, \eta_2 < 1$  为比例系数,  $\eta_1 + \eta_2 = 1$ 。  $K_w$  为加权峭度, 综合考虑峭度和相关系数两个指标, 定义如下:

$$K_w = K \cdot |C| \quad (17)$$

$$K = \frac{\frac{1}{N} \sum_{n=1}^N x^4(n)}{\left[ \frac{1}{N} \sum_{n=1}^N x^2(n) \right]^2} \quad (18)$$

$$C = \frac{\sum_{n=1}^N [x(n) - \bar{x}][y(n) - \bar{y}]}{\sqrt{\sum_{n=1}^N (x(n) - \bar{x})^2 \sum_{n=1}^N (y(n) - \bar{y})^2}} \quad (19)$$

式中  $\bar{x}, \bar{y}$  分别为相应的  $x, y$  的平均值;  $K$  为信号  $x$  的峭度;  $N$  为信号  $x$  的长度;  $C$  为信号  $x$  和  $y$  之间的相关系数, 在本文中指各 CSGMCs 与原始信号之间的相关系数。

$K_c$  为合成峭度, 综合考虑峭度和包络谱的优势, 定义如下:

$$K_c = \frac{\sum_{j=1}^p |s_e(j)|^4}{\left(\sum_{j=1}^p |s_e(j)|^2\right)^2} \cdot K \quad (20)$$

式中 右边第1项为包络幅值峭度;  $s_e$  为信号包络谱;  $p$  表示包络谱采样点数。  $\eta_1$  和  $\eta_2$  的确定采用粒子群优化算法<sup>[22]</sup>, 并根据文献[16, 23], 选择  $Q$  值最大的前4个分量进行重构。

#### 1.4 仿真实验

为验证 ESGMD 的分解效果, 进行仿真信号分析, 设仿真信号  $f(t)$  由3个分量叠加而成, 如下式所示:

$$\begin{cases} f(t) = f_1(t) + f_2(t) + f_3(t) \\ f_1(t) = \cos(40\pi t) \\ f_2(t) = 0.64\cos(60\pi t - 3\cos 20t) \\ f_3(t) = \text{awgn}(x, \text{SNR}) \end{cases} \quad (21)$$

式中  $f_1(t)$  为余弦信号;  $f_2(t)$  为调频信号;  $f_3(t)$  为高斯白噪声函数;  $\text{SNR}$  为信噪比, 本节取 10 dB。分别采用 ESGMD 和 SGMD 对  $f(t)$  进行分解, 如图1~2所示。根据综合评价指标大小, 选取图1中的




图1 ESGMD 分解结果

Fig. 1 The decomposition results of ESGMD




图2 SGMD 分解结果

Fig. 2 The decomposition results of SGMD

CSGMC1 和 CSGMC2 和图2中的 SGMC1~SGMC4 分量进行重构分析, 其重构后的时频谱与原信号的 HHT 时频谱如图3~5所示。




图3 原信号 HHT 时频谱

Fig. 3 HHT time-frequency spectrum of raw signal




图4 SGMD 时频谱

Fig. 4 SGMD time-frequency spectrum

由图1和2可知, ESGMD 的分解模态数明显少于 SGMD 方法。由图3~5可知, HHT 产生了严重的模态混叠现象, ESGMD 方法分解出的 ESGMD1 和 ESGMD2 分量分别对应于  $f_1(t)$  和  $f_2(t)$ , 没有出现模态混叠现象, 仿真结果表明 ESGMD 相比于 SGMD 能较为准确地分解仿真信号, 对噪声鲁棒性较强。




图5 ESGMD时频谱

Fig. 5 ESGMD time-frequency spectrum

## 2 自组织自编码卷积网络

### 2.1 自编码卷积网络

小波自编码器 (wavelet auto-encoder, WAE)<sup>[3]</sup> 既具有无监督特征学习能力,又具备小波函数时频聚焦特性,但其为全连接网络,训练速度慢;而 CNN<sup>[24]</sup> 具有稀疏连接性质,可有效减少网络间的连接。因此本文将 WAE 和 CNN 结合,构造自编码卷积网络 (Auto-Encoder Convolution Network, AECN),如图 6 所示。




图6 AECN结构

Fig. 6 The structure of AECN

设输入  $x$ , 则 AECN 隐层第  $k$  个节点输出如下:

$$h^k = \psi[(x * W^k - c^k) / a^k] \quad (22)$$

$$\psi(t) = \frac{t}{\sqrt{2\pi}} \exp\left(-\frac{t^2}{2}\right) \quad (23)$$

式中  $\psi$  为高斯小波;  $W^k$  为卷积核权重;  $a^k$  和  $c^k$  分别为隐层小波节点的尺度向量和平移向量;  $*$  为卷积符号;  $/$  为按元素相除符号。重构信号如下:

$$y = \text{Sigmoid}\left[\sum_{k=1}^L h^k * W_T^k + b\right] \quad (24)$$

$$\text{Sigmoid}(t) = 1 / (1 + e^{-t}) \quad (25)$$

式中  $L$  为隐层节点个数;  $W_T^k$  为反卷积核权重矩阵转置;  $b$  为偏置。

### 2.2 自组织策略

首先,将 AECN 的隐层节点激活值作为节点“贡献度”,并根据“贡献度”大小对节点进行增加或删除;其次,在微调阶段,当损失函数梯度下降率首次出现递减时删掉一个隐层,否则增加一个隐层,激活强度  $S_i^l$  计算如下:

$$S_i^l = \alpha \frac{s_{i,l}^2}{1 + s_{i,l}^2 + o_{i,l}^2}, i = 1, 2, 3, \dots, N_l \quad (26)$$

式中  $\alpha > 0$  为常数;  $o_{i,l}$  为第  $l$  个隐层的第  $i$  个节点的输出;  $N_l$  为第  $l$  个隐层节点个数;  $s_{i,l}$  为第  $l$  个隐层的第  $i$  个节点的输入权值之和,如下式所示:

$$s_{i,l}^2 = \sum_{j=1}^{n_i} w_{ij} r_{ij} \quad (27)$$

式中  $n_i$  为神经元的个数;  $r_{ij}$  为第  $i$  个节点的第  $j$  个输入;  $w_{ij}$  为第  $j$  个节点和第  $i$  个节点的连接权重。自组织策略流程如图 7 所示。




图7 自组织策略

Fig. 7 The self-organizing strategy

### 2.3 改进损失函数

AECN 的均方损失函数如下:

$$J = \sum_{i=1}^N L(x_i, y_i) = \sum_{i=1}^N \|y_i - x_i\|_2^2 \quad (28)$$

式中  $x_i$  为输入样本;  $y_i$  为重构样本;  $N$  为样本数目。

为提高 AECN 的特征提取性能,在式 (28) 的基础上加入一阶和二阶收缩惩罚项。一阶和二阶收缩惩罚项的计算分别如下:

$$\|J_f(x)\|_F^2 = \sum_{ij} \left( \frac{\partial h_j(x)}{\partial x_i} \right)^2 \quad (29)$$

$$\|H_f(x)\|_F^2 = \left\| \frac{\partial J_f(x)}{\partial x} \right\|_F^2 \quad (30)$$

均方损失函数使 AECN 的重构误差尽量小,一

阶和二阶收缩惩罚项使 AECN 对输入的扰动具有一定的不变性。同时,为使 AECN 学习的隐层特征对输入信号的结构变化具有可分辨性,增加可分辨惩罚项,计算如下:

$$\text{Tr}(\boldsymbol{S}_w)-\text{Tr}(\boldsymbol{S}_b) \tag{31}$$

$$\boldsymbol{S}_w=\sum_{k=1}^L\sum_{n\in C_k}(\boldsymbol{h}_n-\boldsymbol{m}_k)(\boldsymbol{h}_n-\boldsymbol{m}_k)^T \tag{32}$$

$$\boldsymbol{S}_b=\sum_{k=1}^L N_k(\boldsymbol{m}_k-\boldsymbol{m})(\boldsymbol{m}_k-\boldsymbol{m})^T \tag{33}$$

$$\boldsymbol{m}_k=\frac{\sum_{n\in C_k}\boldsymbol{h}_n}{N_k} \tag{34}$$

$$\boldsymbol{m}=\frac{\sum_{n=1}^N\boldsymbol{h}_n}{N} \tag{35}$$

式中  $\boldsymbol{h}_n$  为 AECN 的隐层特征;  $N_k$  为工况  $C_k$  的样本数,  $L$  为工况类别数;  $\text{Tr}()$  为取矩阵的迹操作。综上, AECN 的损失函数如下:

$$J_{\text{SOAECN}}=\sum_{i=1}^N\|\boldsymbol{y}_i-\boldsymbol{x}_i\|_2^2+\beta\|\boldsymbol{J}_f(\boldsymbol{x})\|_F^2+\eta\|\boldsymbol{H}_f(\boldsymbol{x})\|_F^2+\lambda(\text{Tr}(\boldsymbol{S}_w)-\text{Tr}(\boldsymbol{S}_b)) \tag{36}$$

式中  $\beta$ ,  $\eta$  和  $\lambda$  分别为一阶收缩惩罚项系数、二阶收缩惩罚项系数和可分辨惩罚项系数。采用文献[25]的小批量随机梯度下降算法, AECN 各参数更新公式如下式所示:

$$\begin{cases} \boldsymbol{W}_{k+1}\leftarrow\boldsymbol{W}_k-\frac{\eta_k}{B_k}\sum_{n=1}^{B_k}\nabla J_{i_k}(\boldsymbol{W}_k) \\ \boldsymbol{a}_{k+1}\leftarrow\boldsymbol{a}_k-\frac{\eta_k}{B_k}\sum_{n=1}^{B_k}\nabla J_{i_k}(\boldsymbol{a}_k) \\ \boldsymbol{c}_{k+1}\leftarrow\boldsymbol{c}_k-\frac{\eta_k}{B_k}\sum_{n=1}^{B_k}\nabla J_{i_k}(\boldsymbol{c}_k) \end{cases} \tag{37}$$

式中  $i_k\in\{1,2,\cdots,n\}$ ,  $B_k$  和  $\eta_k$  分别为第  $k$  次参数更新过程中的序号、样本数量和学习率。综上,提出方法流程如图 8 所示,详细步骤如下:




图 8 ESGMD-SOAECN 算法流程

Fig. 8 The algorithm flow of ESGMD-SOAECN

- (1)采集电机轴承振动信号样本,并划分为训练样本和测试样本;
- (2)对样本进行 ESGMD 分解,利用综合评价指标  $Q$  选择特征信息明显的 4 个分量并重构;
- (3)将重构后的训练样本输入 SOAECN 进行无监督预训练和有监督微调训练;
- (4)使用测试样本对训练好的网络进行测试。

3 实验验证

3.1 数据描述

为验证 ESGMD-SOAECN 的有效性,采用如图 9 所示的实验台进行验证。




图 9 电机轴承实验台

Fig. 9 The test bench of motor bearing

实验台由感应电机、电机速度控制器、加载系统等组成,加速度计位于被测轴承外壳上,采样频率为 25.6 kHz。使用电火花技术在轴承内圈、外圈和滚动体上加工尺寸为 0.15 和 0.32 mm 的环槽损伤。参考文献[26-28]的工况设置方法,选取 11 种工况进行研究,如表 1 所示。每种工况 8000 个样本,每个样

表 1 电机轴承 11 种工况

Tab. 1 Eleven working conditions of motor bearings

| 运行工况       | 代号 | 转速/<br>Hz | 负载/<br>kN | 故障尺<br>寸/mm |
|------------|----|-----------|-----------|-------------|
| 正常         | a  | 40        | 10        | 0           |
| 内圈轻微故障     | b  | 35        | 9         | 0.15        |
| 内圈轻微故障     | c  | 30        | 8         | 0.32        |
| 外圈轻微故障     | d  | 35        | 10        | 0.15        |
| 外圈轻微故障     | e  | 30        | 9         | 0.32        |
| 滚动体轻微故障    | f  | 30        | 8         | 0.15        |
| 滚动体轻微故障    | g  | 40        | 10        | 0.32        |
| 滚动体+内圈轻微故障 | h  | 35        | 9         | 0.15        |
| 滚动体+内圈中度故障 | i  | 30        | 10        | 0.32        |
| 滚动体+外圈轻微故障 | j  | 35        | 9         | 0.15        |
| 滚动体+外圈轻微故障 | k  | 30        | 8         | 0.32        |

本1024个采样点。相应的时域波形图、频谱图及包络谱图分别如图10~12所示。由图可知,信号受噪声干扰严重,直接从时域图、频谱图及包络谱图中完全区分电机轴承运行工况类别及故障工况程度较难。




图10 电机轴承振动信号时域波形

Fig. 10 Time-domain waveform of vibration signals of motor bearing

### 3.2 实际信号分解

以表1中工况c信号为例,其时频谱图如图13所示。

由图13可知,原始信号时频谱模态混叠严重,时频谱杂乱,然后分别采用ESGMD和SGMD对其进行分解,如图14和15所示。

由图14和15可知,ESGMD分解模态数少于SGMD。并根据综合评价指标Q选择较大的4个分量进行重构,对重构后的信号进行相应的时频变换,分别如图16和17所示。

由下式求得轴承外圈故障特征频率约107.89 Hz。

$$f_o = \frac{1}{2} f_r \left(1 - \frac{d}{D} \cos \alpha\right) Z \quad (38)$$




图11 电机轴承振动信号频谱图

Fig. 11 Spectrum of vibration signals of motor bearing

式中  $d$  为滚子直径; $D$  为节圆直径; $\alpha$  为接触角; $Z$  为滚子数; $f_r=35$  Hz 为转频。

图17中SGMD时频谱,时频谱线仍然杂乱,故障特征频率难以分辨;图16中ESGMD时频谱脊线较明显,故障特征频率及倍频较清晰,验证了ESGMD的优越性。

### 3.3 不同方法的对比分析

首先验证SOAECN的效果,采用AE,WAE和AECN(无自组织策略)进行对比分析。其中,方法1:ESGMD-SOAECN;方法2:ESGMD-AE;方法3:ESGMD-WAE;方法4:ESGMD-AECN。SOAECN的初始结构为1024-512-256-128-64-11;AE,WAE和AECN的结构均为1024-512-256-128-64-11。表2列出了不同方法10次实验的平均工况识别率和训练用时。

由表2可知,本文方法具有更高的工况识别准确率(98.76%)和更小的标准差(0.19);AE由于均方损失函数易受噪声干扰的缺陷导致识别率较低;




图12 电机轴承振动信号包络谱图

Fig. 12 Envelope spectrum of vibration signals of motor bearing




图13 原始信号时频谱

Fig. 13 Time-frequency spectrum of raw signals

WAE小波函数的时频聚焦特性一定程度上提高了识别准确率;AECN在WAE基础上使用了卷积机制,减少了网络所需调整参数,识别准确率优于WAE,且收敛时间短于WAE;而SOAECN在AECN基础上改进了网络损失函数,加入了自组织策略,改进的损失函数提升了网络的工况识别率,但自组织策略一定程度增加了网络的训练时间。




图14 ESGMD分解结果

Fig. 14 The decomposition results of ESGMD




图15 SGMD分解结果

Fig. 15 The decomposition results of SGMD

其次验证ESGMD的效果,采用不同的信号分解方法进行对比分析。方法1:ESGMD-SOAECN;方法2:CEEWD-SOAECN;方法3:SGMD-SOAECN;方法4:VMD-SOAECN;方法5:Raw-SOAECN(原始信号直接输入SOAECN);方法6:FFT-SOAECN(频谱输入SOAECN);方法7:Envelope-SOAECN(包络谱输入SOAECN)。各信号




图 16 ESGMD时频谱

Fig. 16 Time-frequency spectrum of ESGMD




图 17 SGMD时频谱

Fig. 17 Time-frequency spectrum of SGMD

表 2 不同方法的识别结果

Tab. 2 Identification results of different methods

| 方法           | 平均识别率/%<br>± 标准差 | 训练时间/s |
|--------------|------------------|--------|
| ESGMD-SOAECN | 98.76 ± 0.19     | 467.43 |
| ESGMD-AE     | 93.21 ± 2.97     | 248.87 |
| ESGMD-WAE    | 94.65 ± 2.06     | 361.66 |
| ESGMD-AECN   | 96.82 ± 1.08     | 277.87 |

表 3 不同信号输入方法的工况识别结果

Tab. 3 Working conditions identification results of different signal input methods

| 方法              | 平均识别率/%<br>± 标准差 |
|-----------------|------------------|
| ESGMD-SOAECN    | 98.76 ± 0.19     |
| CEEMD-SOAECN    | 94.79 ± 2.68     |
| SGMD-SOAECN     | 96.10 ± 0.37     |
| VMD-SOAECN      | 94.83 ± 1.63     |
| Raw-SOAECN      | 93.19 ± 3.01     |
| FFT-SOAECN      | 93.85 ± 2.98     |
| Envelope-SOAECN | 94.66 ± 1.71     |

分解方法选择Q值最大的前4个分量进行重构,表3列出了不同方法10次实验的工况识别率。

由表3可知,CEEMD由于模态混叠严重导致工况识别率较低;VMD改进了CEEMD模态混叠的缺陷,识别效果略优于CEEMD;SGMD能有效保持

时间序列的本质特征,模态混叠现象进一步降低,效果优于VMD;而ESGMD采用改进凝聚聚类算法对ISGMCs进行自适应重组,进一步增强了信号的特征表达,效果优于SGMD;若直接将原始信号输入SOAECN,噪声的存在使得网络的工况识别率仅93.19%,验证了信号降噪前处理的必要性;若直接将频谱或包络谱信号输入SOAECN,识别效果低于ESGMD方法。

3.4 不平衡数据集下工况识别率

实际工程中正常工况样本所占比例通常较高,因此本文设计4种数据集,比较不同方法的工况识别性能。设置正常工况与故障工况的样本比例分别为8000:8000,8000:6400,8000:4800和8000:4000,实验共进行10次,本文定量计算3种方法基于不平衡数据集的精确率 $F_1$ 值,如下式所示:

$$F_1 = \frac{2PR}{P + R} \tag{39}$$

式中  $P$  为精确率; $R$  为召回率。 $F_1$  值在 $[0,1]$ 之间,0代表最差,1代表最好。以组3为例,表4列出了相应的 $F_1$ 值。

表 4 组 3 中不同方法的  $F_1$  值

Tab. 4  $F_1$  of different methods in group 3

| 工况 | ESGMD-SOAECN | SGMD-SOAECN | ESGMD-AECN |
|----|--------------|-------------|------------|
| a  | 0.952        | 0.923       | 0.921      |
| b  | 0.953        | 0.911       | 0.909      |
| c  | 0.961        | 0.929       | 0.918      |
| d  | 0.960        | 0.919       | 0.913      |
| e  | 0.959        | 0.921       | 0.919      |
| f  | 0.941        | 0.911       | 0.920      |
| g  | 0.946        | 0.901       | 0.913      |
| h  | 0.960        | 0.909       | 0.915      |
| i  | 0.959        | 0.881       | 0.908      |
| j  | 0.942        | 0.911       | 0.891      |
| k  | 0.946        | 0.901       | 0.890      |

由表4可知,组3中ESGMD-SOAECN的 $F_1$ 指标值较高,进一步验证了ESGMD-SOAECN在面对不平衡数据集的优势。

3.5 不同激活函数对工况识别率的影响

本节讨论几种不同激活函数对SOAECN识别准确率的影响,结果如表5所示。由表5可知,Gaussian小波、Morlet小波和Mexican hat小波的工况识别效果优于其他激活函数,Gaussian小波在时域、频域均有良好的分辨率,取得了更好的识别结果。

表 5 不同激活函数对 SOAECN 识别准确率的影响

Tab. 5 Influence of different activation functions on SOAECN identification accuracy

| 激活函数                | 方程                                                                       | 识别率/% |
|---------------------|--------------------------------------------------------------------------|-------|
| ReLU                | $f(x)=\begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases}$             | 95.14 |
| LReLU               | $f(x)=\begin{cases} 0.01x, & x < 0 \\ x, & x \geq 0 \end{cases}$         | 95.82 |
| ELU                 | $f(x)=\begin{cases} 0.01(e^x - 1), & x < 0 \\ x, & x \geq 0 \end{cases}$ | 94.64 |
| Sigmoid             | $f(x)=\frac{1}{1+e^{-x}}$                                                | 93.47 |
| Gaussian wavelet    | $f(x)=\frac{x}{\sqrt{2\pi}}\exp(-\frac{x^2}{2})$                         | 98.76 |
| GELU                | $f(x)=0.5x\{1+\tanh[\sqrt{2/\pi}(x+0.044715x^3)]\}$                      | 96.42 |
| Swish               | $f(x)=\frac{x}{1+e^{-x}}$                                                | 96.17 |
| Morlet wavelet      | $f(x)=\cos(5x)\exp(-\frac{x^2}{2})$                                      | 98.02 |
| Mexican hat wavelet | $f(x)=(1-x^2)\exp(-\frac{x^2}{2})$                                       | 98.09 |

3.6 跨工况识别研究

实际工程中电机通常在变工况下运行,本节验证了提出方法在跨工况下的泛化能力,使用带标签的源域信号样本对无标签的目标域信号样本进行识别,带标签样本仅作源域数据使用,以工况 b~k 为例,结果如表 6 所示。由表 6 可知,ESGMD-SOAECN 的跨工况识别结果的平均识别准确率在 92% 以上,这表明所提方法有一定的跨工况识别能力,后续将进行进一步研究,提升模型的跨工况识别准确率。

表 6 跨工况识别结果

Tab. 6 Identification results of across the working condition

| 跨工况任务            | 平均识别率/% |
|------------------|---------|
| 源域:工况 b→目标域:工况 c | 93.08   |
| 源域:工况 d→目标域:工况 e | 93.97   |
| 源域:工况 f→目标域:工况 g | 93.18   |
| 源域:工况 h→目标域:工况 i | 92.10   |
| 源域:工况 j→目标域:工况 k | 92.46   |

4 结 论

本文提出一种 ESGMD-SOAECN 的电机轴承工况识别方法,主要结论如下:

(1) ESGMD 信号分解方法采用改进凝聚聚类算法缓解了 SGMD 的模式混叠现象;提出一种

综合评价指标能较好地筛选出较能反映电机轴承振动信号特征的聚类辛几何模态分量并重构,为后续 SOAECN 自动工况识别提供优秀的训练样本。

(2) SOAECN 引入自组织策略,在训练过程中自适应动态变化,更适用于非线性和非平稳性电机轴承振动信号;在均方损失函数的基础上加入一阶收缩惩罚项、二阶收缩惩罚项和可分辨惩罚项,提升了网络对输入信号微小变化的鲁棒性和信号结构变化的可分辨性。

(3) 引入的自组织策略耗时多,部署到工业环境中实时性不够,这也是今后需要改进的方面。

参考文献:

[1] 周陈林,董绍江,李玲,等.滚动轴承多状态特征信息的改进型卷积神经网络故障诊断方法[J].振动工程学报,2020,33(4):854-860.  
Zhou Chenlin, Dong Shaojiang, Li Ling, et al. Method to improve convolutional neural network in rolling bearing fault diagnosis with multi-state feature information [J]. Journal of Vibration Engineering, 2020, 33 (4) : 854-860.

[2] Lu C, Wang Z Y, Qin W L, et al. Fault diagnosis of rotary machinery components using a stacked denoising autoencoder-based health state identification[J]. Signal Processing, 2017, 130: 377-388.

[3] Shao H D, Jiang H K, Li X Q, et al. Intelligent fault di-

- agnosis of rolling bearing using deep wavelet auto-encoder with extreme learning machine [J]. Knowledge-Based Systems, 2018, 140: 1-14.
- [4] Shao H D, Jiang H K, Wang F A, et al. An enhancement deep feature fusion method for rotating machinery fault diagnosis [J]. Knowledge-Based Systems, 2017, 119: 200-220.
- [5] Shao H D, Jiang H K, Lin Y, et al. A novel method for intelligent fault diagnosis of rolling bearings using ensemble deep auto-encoders [J]. Mechanical Systems and Signal Processing, 2018, 102: 278-297.
- [6] Shao H D, Jiang H K, Zhang H Z, et al. Rolling bearing fault feature learning using improved convolutional deep belief network with compressed sensing [J]. Mechanical Systems and Signal Processing, 2018, 100: 743-765.
- [7] Zhang W D, Zhang F, Chen W, et al. Fault state recognition of rolling bearing based fully convolutional network [J]. Computing in Science & Engineering, 2019, 21(5): 55-63.
- [8] Shao H D, Jiang H K, Zhang H Z, et al. Electric locomotive bearing fault diagnosis using novel convolutional deep belief network [J]. IEEE Transactions on Industrial Electronics, 2017, 65(3): 2727-2736.
- [9] Han D Y, Zhao N, Shi P M. A new fault diagnosis method based on deep belief network and support vector machine with Teager-Kaiser energy operator for bearings [J]. Advances in Mechanical Engineering, 2017, 9(12): 168781401774311.
- [10] Liao Ning, Tao Jie, Yang Dalian. Fault diagnosis for double row tapered roller bearing based on deep learning method and EMD [J]. Journal of Hunan University of Science & Technology (Natural Science Edition), 2017, 32(2): 70-77.
- [11] Liu X F, Bo L, Luo H L. Bearing faults diagnostics based on hybrid LS-SVM and EMD method [J]. Measurement, 2015, 59: 145-166.
- [12] Wang J J, Gao R X, Yan R Q. Integration of EEMD and ICA for wind turbine gearbox diagnosis [J]. Wind Energy, 2014, 17(5): 757-773.
- [13] Smith J S. The local mean decomposition and its application to EEG Perception data [J]. Journal of the Royal Society Interface, 2005, 2(5): 443-454.
- [14] Dragomiretskiy K, Zosso D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [15] Gilles J. Empirical wavelet transform [J]. IEEE Transactions on Signal Processing, 2013, 61(16): 3999-4010.
- [16] 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.
- [17] 程正阳, 王荣吉, 潘海洋. 辛几何模态分解方法及其分解能力研究 [J]. 振动与冲击, 2020, 39(13): 27-35. Cheng Zhengyang, Wang Rongji, Pan Haiyang. Symplectic geometry mode decomposition method and its decomposition ability [J]. Journal of Vibration and Shock, 2020, 39(13): 27-35.
- [18] 郑直, 王宝中, 刘佳鑫, 等. 辛几何模态分解和广义形态分形维数的液压泵故障诊断 [J]. 哈尔滨工程大学学报, 2020, 41(5): 724-730. Zheng Zhi, Wang Baozhong, Liu Jiaxin, et al. Hydraulic pump fault diagnosis method of symplectic geometry mode decomposition and generalized morphological fractal dimensions [J]. Journal of Harbin Engineering University, 2020, 41(5): 724-730.
- [19] Kaveh H, Salarieh H, Hajiloo R. On the control of unknown continuous time chaotic systems by applying Takens embedding theory [J]. Chaos, Solitons and Fractals, 2018, 109: 53-57.
- [20] Kim H S, Eykholt R, Salas J D. Nonlinear Dynamics, Delay Times, and Embedding Windows [M]. Elsevier Science Publishers B. V., 1999.
- [21] Yang W T, He Z J, Huang H K, et al. A clustering framework to reveal the structural effect mechanisms of natural and social factors on PM 2.5 concentrations in China [J]. Sustainability, 2021, 13(3): 1-15.
- [22] Blackwell T. A study of collapse in bare bones particle swarm optimization [J]. IEEE Transactions on Evolutionary Computation, 2012, 16(3): 354-372.
- [23] Zheng Z, Xin G. Fault feature extraction of hydraulic pumps based on symplectic geometry mode decomposition and power spectral entropy [J]. Entropy, 2019, 21(5): 476.
- [24] Wen L, Li X Y, Gao L, et al. A new convolutional neural network based data-driven fault diagnosis method [J]. IEEE Transactions on Industrial Electronics, 2018, 65(7): 5990-5998.
- [25] Nesterov Y. Gradient methods for minimizing composite functions [J]. Mathematical Programming, 2013, 140(1): 125-161.
- [26] Liu X F, Bo L, Luo H L. Bearing faults diagnostics based on hybrid LS-SVM and EMD method [J]. Measurement, 2015, 59: 145-166.

- [27] Jia F, Lei Y G, Lin J, et al. Deep neural networks: a promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data [J]. Mechanical Systems & Signal Processing, 2016, 72-73: 303-315.
- [28] Gan M, Wang C, Zhu C A. Construction of hierarchical diagnosis network based on deep learning and its application in the fault pattern recognition of rolling element bearings[J]. Mechanical Systems and Signal Processing, 2016, 72-73: 92-104.

## Motor bearing condition identification of enhanced symplectic geometric mode decomposition and self-organizing auto-encoder convolution network

CHEN Zhi-gang<sup>1,2</sup>, DU Xiao-lei<sup>3</sup>, WANG Yan-xue<sup>1,4</sup>

(1.School of Machine-Electricity 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.College of Mechanical and Electrical Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China; 4.Beijing Key Laboratory of Performance Guarantee on Urban Rail Transit Vehicles, Beijing 100044, China)

**Abstract:** Aiming at the difficulty of vibration signals feature extraction and condition identification of motor bearings, a method based on enhanced symplectic geometry mode decomposition (ESGMD) with self-organizing auto-encoder convolution network (SOAECN) is proposed. On the basis of symplectic geometry mode decomposition (SGMD), the vibration signals of motor bearing are adaptively decomposed into initial symplectic geometric mode component (ISGMCs). The ISGMCs are adaptively reorganized by improved condensed clustering method to obtain the clustering symplectic geometric modal components (CSGMCs). A new comprehensive evaluation index is proposed, which is used to screen and reconstruct the CSGMCs that can reflect the characteristics of vibration signals. Combined convolution neural network with wavelet auto-encoder, the auto-encoder convolution network (AECN) is constructed. Its loss function is improved and self-organizing strategy is introduced on the basis of AECN, then the SOAECN is constructed. The reconstructed vibration signals are fed into SOAECN for automatic feature learning and condition identification. Experimental results indicate that ESGMD-SOAECN reaches 98.98% of condition identification rate. The ability of condition automatic feature extraction and automatic condition identification is better than deep learning methods such as deep sparse auto-encoder, deep de-noising auto-encoder, deep belief network and so on. The results can provide a reference for the identification of motor bearing conditions.

**Key words:** fault diagnosis; bearing; condition identification; symplectic geometry mode decomposition; self-organizing auto-encoder convolution network; improved condensed clustering

作者简介: 陈志刚(1979—),男,博士,教授。电话: 13521909643; E-mail: gangzi22@163.com。

通讯作者: 杜小磊(1993—),男,博士研究生。电话: 13260417530; E-mail: 13260417530@163.com。