

# 多维度能量熵提取的不同负载下电机轴承故障诊断

唐 鸣, 王爱元, 朱振田  
(上海电机学院 电气学院 上海 201306)

**摘 要:** 为了提高电机轴承故障诊断的准确率, 针对电机轴承故障不稳定的振动信号及故障特征提取困难问题, 提出了一种基于变分模态分解(VMD)能量熵与卷积神经网络(CNN)相结合的电机轴承故障诊断方法。为了使故障的特征更精确地体现出来, 采取三维度的能量熵提取办法, 将轴承故障分为内圈磨损、外圈磨损和保持架断裂三类, 然后每个类别再细分为负载为 0%、25% 和 50% 三种情况, 共 9 种情况。利用 VMD 方法将故障信号分解得到内禀模态函数(IMF)的分量并提取各个维度 IMF 的能量熵值从而构成特征向量。结果表明该方法可以有效提高故障诊断正确率。

**关键词:** 轴承故障诊断; 变分模态分解; 三维能量熵; 卷积神经网络

中图分类号: TM341 文献标志码: A 文章编号: 1673-6540(2023)09-0063-07

doi: 10.12177/emca.2023.102

## Fault Diagnosis of Motor Bearings with Different Loads Based on Multi-Dimensional Energy Entropy Extraction

TANG Ming, WANG Aiyuan, ZHU Zhentian

(School of Electrical Engineering, Shanghai Dianji University, Shanghai 201306, China)

**Abstract:** In order to improve the accuracy of motor bearing fault diagnosis, and aiming at the problem of unstable vibration signals and the difficulty in extracting fault feature of motor bearing fault, a motor bearing fault diagnosis method based on the combination of variational mode decomposition (VMD) energy entropy and convolutional neural network (CNN) is proposed. In order to reflect the characteristics of faults more accurately, a three-dimensional energy entropy extraction method is adopted to divide the bearing faults into three categories, namely, inner ring wear, outer ring wear and cage fracture. Then each category is subdivided into three cases with loads of 0%, 25% and 50%, for a total of 9 cases. Firstly, the VMD method is used to decompose the fault signal into components of the intrinsic mode function (IMF) and the energy entropy of each dimension IMF is extracted to form the feature vector. The results show that the method can effectively improve the accuracy of fault diagnosis.

**Key words:** bearing fault diagnosis; variational mode decomposition (VMD) three-dimensional energy entropy; energy entropy; convolutional neural network (CNN)

## 0 引 言

电机轴承对于电机来说是一个至关重要的部件, 轴承一旦损坏, 就会对电机的运行造成严重的

影响。当轴承发生故障时, 要迅速诊断出轴承哪个部位发生问题, 并及时修复轴承, 恢复运行。故障诊断最关键的两个步骤就是故障提取和模式识别。文献[1]采用了改进的时变变换的方法进行

收稿日期: 2023-04-02; 收到修改稿日期: 2023-04-18

作者简介: 唐 鸣(1999—), 男, 硕士研究生, 研究方向为电机故障诊断。

王爱元(1968—), 男, 博士, 教授, 研究方向工程电磁场计算分析、电动机节能控制等。(通信作者)

降噪然后将特征值提取出来,再对电机的故障类型进行识别。文献[2]先对电机的轴承进行分析,后采用正交小波对故障出现的位置进行诊断。文献[3]在传统模态分解法的基础上,提出了集合经验模态分解法(EEMD),有效避免了模态混叠,但是会造成信号分解的数量出现不同和算法效率低下的问题。文献[4]提出了基于变分模态分解与散布熵(VMD-DE)的坦克行星变速箱故障诊断方法,将变分模态分解(VMD)与散布熵(DE)结合提取其故障特征向量,从而提高故障模式识别的准确率。文献[5]提出了基于VMD的滚动轴承早期故障诊断方法,对采集得到的轴承故障信号用VMD分解提取故障特征输入到包络谱进行分析来判断故障类型。文献[6]提出了一种基于VMD和自回归(AR)模型为基础的转子裂纹故障诊断方法,利用VMD方法得到若干个平稳的本征模态函数并建立各分量的AR模型,把模型参数和残差的方差作为系统状态特征向量。文献[7]提出了小波包能量熵与深度置信网络(DBN)结合的方法对轴承故障进行诊断。先利用小波包分解轴承的故障振动信号,再以能量熵的形式组成特征向量,采用DBN的深度模型对能量熵特征向量进行故障识别。文献[8]采用了一维卷积神经网络的轴承故障诊断方法,在此基础上对超参数进行调节,最终得到了一个较好的模型。本文则采取VMD分解三个维度的故障振动信号并提取能量熵作为特征向量,使得故障的特征更精确地表现出来并输入到CNN模型进行训练并验证<sup>[9]</sup>。

## 1 VMD分解与能量熵提取

### 1.1 VMD分解原理

变分模态分析是一种应用于信号分析中的分析方法。该方法在获得分解成分时,用迭代式搜索变分模型的最优解,来决定各个成分的频率中心和带宽,这样就可以对信号进行频域剖分,并对各个成分进行有效地分离<sup>[10-11]</sup>。

利用VMD算法将故障信号分成若干个“本征模态函数”,可以表示为

$$u_k(t) = w_k(t) \cos[\varphi_k(t)] \quad (1)$$

式中: $u_k(t)$ 为VMD分解后的第 $k$ 个的信号分量; $w_k(t)$ 为信号的瞬时幅值; $\varphi_k(t)$ 为信号的相位。

信号的瞬时频率 $\omega_k(t)$ 的表达式为

$$\omega_k(t) = d\varphi_k(t)/dt \quad (2)$$

通过VMD分解,可以得到 $k$ 个模态分量 $u_k(t)$ ,为了确保原信号和各个模态分量相等,使每个分量估计带宽之和最小,并确定各个分量的中心频率。

VMD算法的具体的步骤如下:

(1) 通过Hilbert变化计算出各个模态分量 $u_k(t)$ 的单边频谱:

$$\left[ \delta(t) + \frac{j}{\pi t} \right] * u_k(t) \quad (3)$$

(2) 对每一种模态分量,求出一个大概中心频率 $\omega_k$ ,再把单边频谱转化为基频带,其表达式如下:

$$\left\{ \left[ \delta(t) + \frac{j}{\pi t} \right] * u_k(t) \right\} e^{-j\omega t} \quad (4)$$

(3) 计算出基频带梯度范数的 $L^2$ ,求出大概的各个分量的带宽。

$$\left\| dt \left\{ \left[ \delta(t) + \frac{j}{\pi t} \right] * u_k(t) \right\} * e^{-j\omega t} \right\|_2^2 \quad (5)$$

采用VMD算法分解信号时,将会受到约束,约束的表达式为

$$\begin{aligned} \min & \left\{ \sum_k \left\| dt \left\{ \left[ \delta(t) + \frac{j}{\pi t} \right] * u_k(t) \right\} e^{-j\omega t} \right\|_2^2 \right\} \\ \text{s. t.} & \sum_k u_k(t) = x(t) \end{aligned} \quad (6)$$

式中: $\delta(t)$ 为单位脉冲函数; $*$ 是卷积; $dt$ 是对函数求导; $\text{s. t.}$ 是约束条件。

对式(6)引入二次惩罚因子 $\alpha$ 和拉格朗日乘法算子 $\lambda(t)$ 后,其表达式如下:

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_k \left\| dt \left\{ \left[ \delta(t) + \frac{j}{\pi t} \right] * u_k(t) \right\} e^{-j\omega t} \right\|_2^2 + \\ & \left\| x(t) - \sum_k u_k(t) \right\|_2^2 + \\ & \langle \lambda(t)x(t) - \sum_k u_k(t) \rangle \end{aligned} \quad (7)$$

使用交替向乘法(ADMM)算法进行不断地循环迭代,直到搜索到拉格朗日函数 $L$ 的最小值,停止迭代,并更新 $u_k$ 、 $\omega_k$ 、 $\lambda$ 直到满足收敛误差 $\varepsilon$ 大于相对误差 $e$ 。

### 1.2 能量熵

通过VMD分解电机轴承故障信号,可以得到不同的内禀模态函数(IMF)分量。由于故障信号

不同,其中的能量也各不相同。能量分布在所分解的各个分量中,可以作为特征向量来反映故障信号<sup>[12-13]</sup>。能量熵的表达式为<sup>[14]</sup>

$$H_i = - \sum_{r=1}^n p_r \ln p_r \quad (8)$$

式中: $p_r$  为第  $r$  个 IMF 分量的能量在总能量  $E_{\text{sum}}$  中的占比,  $p_r = E_r/E_{\text{sum}}$ ;  $H_i$  表示第  $i$  个 IMF 能量熵,  $i = (1, 2, \dots, n)$ 。

## 2 卷积神经网络

卷积神经网络(CNN)由输入层、卷积层、池化层、全连接层以及输出层组成。通过构造合适的网络结构与参数组合,使原始样本数据在卷积层和池化层进行交替迭代,目的是达到对样本数据进行特征提取和学习。在卷积层中,利用卷积与上一层的特征激活图,对其进行卷积运算,再将操作结果代入到激活函数中,得到卷积层的输出。

第  $i$  卷积核的输出可表示为

$$a^l = f(z^l) = f\left(\sum_{k=1}^k a_k^{l-1} * w_k^l + b^l\right) \quad (9)$$

式中: $k$  是输入特征图的总个数; $f(z^l)$  为激活函数; $w$  为卷积核; $b$  为偏置量。

普通卷积的参数数量大小计算公式为

$$C = Z * Z * K * N \quad (10)$$

式中: $Z$  为卷积核的大小; $K$  为输入特征图的数量; $N$  为输出特征图的数量。

卷积运算图如图 1 所示。




图 1 卷积运算图

## 3 故障诊断流程

由于电机轴承结构的复杂性和故障的相关性,使得其故障信号异常复杂,呈现出非平稳性和

非线性的特征<sup>[15]</sup>。然而,以本文所提出的 VMD 能量熵输入到卷积神经网络故障诊断方法为基础,可以通过 VMD 分解出有用的 IMF 分量。并计算 IMF 分量的能量熵,组成向量特征,代入训练好的 CNN 模型中,进行电机故障诊断<sup>[16-17]</sup>。其流程图如图 2 所示。



图 2 电机故障诊断流程图

## 4 试验结果与分析

### 4.1 试验数据

本次轴承故障数据采用上海某电机厂的轴承数据,轴承故障分为内圈磨损、外圈磨损和保持架断裂三种类别。为了更加全面地诊断轴承情况,每种类别再分为负载 0%、25% 和 50%,共 9 种不同的轴承故障。每个故障类别都提取三个维度的振动信号,即横向、径向和轴向。三个维度的振动信号都进行 VMD 分解,分解出的 IMF 分量再进行能量熵的提取组成特征向量,所以每个故障都有 15 个特征向量,这样提取出的故障信号更加精确,最大程度将故障的特征体现了出来。每种故障取 50 个故障样本,其中 35 个为训练样本,另外 15 个为测试样本。再分别为每种故障贴上标签,例如内圈磨损负载为 0% 的情况为 1,然后根据不同的类别和不同的负载情况依次贴上标签,具体故障数据集如表 1 所示。

### 4.2 VMD 能量熵

VMD 可以对信号中的相似成分进行有效地分离,并且具有良好的鲁棒性,可以有效地解决在信号末端的干扰效果问题。对每组数据样本进行 VMD 分解,其中分解层数  $K$  设置为 5,惩罚因子  $\alpha$  设置为 2 500,其余都设置为默认值。图 3~图 11 分别是各种故障类别的 VMD 分解图,由于篇幅关系只展示每个故障的横向分解图。



表 1 故障数据集

| 故障类型        | 训练集 | 测试集 | 标签 |
|-------------|-----|-----|----|
| 内圈磨损负载 0%   | 35  | 15  | 1  |
| 内圈磨损负载 25%  | 35  | 15  | 2  |
| 内圈磨损负载 50%  | 35  | 15  | 3  |
| 外圈磨损负载 0%   | 35  | 15  | 4  |
| 外圈磨损负载 25%  | 35  | 15  | 5  |
| 外圈磨损负载 50%  | 35  | 15  | 6  |
| 保持架断裂负载 0%  | 35  | 15  | 7  |
| 保持架断裂负载 25% | 35  | 15  | 8  |
| 保持架断裂负载 50% | 35  | 15  | 9  |




图 3 内圈磨损负载为 0% 的分解图




图 4 内圈磨损负载为 25% 的分解图

对比这 9 个分解图的每种故障横向分解图可知,不同频段的能量不相同,故障的径向和轴向分




图 5 内圈磨损负载为 50% 的分解图




图 6 外圈磨损负载为 0% 的分解图




图 7 外圈磨损负载为 25% 的分解图




图 8 外圈磨损负载为 50% 的分解图




图 11 保持架断裂负载为 50% 的分解图

解图亦是如此。在特征提取上采用 VMD 分析进行信号处理比直接进行信号处理更加准确。凭借此特性可以区分出轴承故障状态以及故障的类型。经过 VMD 分解后得到能量熵的故障特征向量,如表 2~表 4 所示。

表 2 横向各故障的特征向量

| 标签 | IMF1    | IMF2    | IMF3    | IMF4    | IMF5    |
|----|---------|---------|---------|---------|---------|
| 1  | 0.105 3 | 0.272 1 | 0.242 8 | 0.276 3 | 0.160 0 |
| 2  | 0.236 2 | 0.353 6 | 0.357 2 | 0.212 4 | 0.150 5 |
| 3  | 0.291 4 | 0.367 0 | 0.359 2 | 0.248 7 | 0.135 5 |
| 4  | 0.029 8 | 0.358 6 | 0.210 9 | 0.192 5 | 0.330 3 |
| 5  | 0.032 5 | 0.206 2 | 0.269 1 | 0.165 3 | 0.125 2 |
| 6  | 0.030 3 | 0.199 3 | 0.281 5 | 0.119 0 | 0.126 8 |
| 7  | 0.085 8 | 0.279 8 | 0.241 7 | 0.317 2 | 0.093 1 |
| 8  | 0.065 8 | 0.367 8 | 0.256 6 | 0.367 6 | 0.233 6 |
| 9  | 0.076 5 | 0.343 3 | 0.264 7 | 0.359 1 | 0.150 0 |

表 3 径向各故障的特征向量

| 标签 | IMF1    | IMF2    | IMF3    | IMF4    | IMF5    |
|----|---------|---------|---------|---------|---------|
| 1  | 0.108 9 | 0.285 8 | 0.119 7 | 0.360 6 | 0.351 2 |
| 2  | 0.183 5 | 0.288 5 | 0.252 0 | 0.257 1 | 0.333 9 |
| 3  | 0.243 7 | 0.275 8 | 0.262 6 | 0.296 8 | 0.357 9 |
| 4  | 0.054 6 | 0.163 3 | 0.229 5 | 0.120 1 | 0.182 5 |
| 5  | 0.090 5 | 0.332 2 | 0.182 2 | 0.360 1 | 0.344 0 |
| 6  | 0.083 6 | 0.218 0 | 0.141 0 | 0.366 9 | 0.346 5 |
| 7  | 0.092 1 | 0.367 8 | 0.116 7 | 0.316 6 | 0.367 8 |
| 8  | 0.080 1 | 0.199 7 | 0.130 9 | 0.256 6 | 0.301 9 |
| 9  | 0.078 9 | 0.198 1 | 0.105 7 | 0.265 5 | 0.320 3 |




图 9 保持架断裂负载为 0% 的分解图




图 10 保持架断裂负载为 25% 的分解图



表 4 轴向各故障的特征向量

| 标签 | IMF1    | IMF2    | IMF3    | IMF4    | IMF5    |
|----|---------|---------|---------|---------|---------|
| 1  | 0.259 4 | 0.367 8 | 0.310 6 | 0.201 4 | 0.342 2 |
| 2  | 0.302 1 | 0.360 9 | 0.349 9 | 0.268 8 | 0.273 2 |
| 3  | 0.299 2 | 0.362 1 | 0.357 2 | 0.257 0 | 0.257 4 |
| 4  | 0.042 9 | 0.367 4 | 0.300 8 | 0.245 3 | 0.367 8 |
| 5  | 0.084 5 | 0.367 9 | 0.294 8 | 0.134 8 | 0.365 6 |
| 6  | 0.077 8 | 0.365 5 | 0.343 2 | 0.107 6 | 0.367 7 |
| 7  | 0.256 8 | 0.338 5 | 0.126 3 | 0.282 7 | 0.298 7 |
| 8  | 0.240 0 | 0.367 5 | 0.203 0 | 0.362 9 | 0.285 6 |
| 9  | 0.202 8 | 0.365 0 | 0.160 5 | 0.355 2 | 0.352 1 |

从表 2~表 4 可以看出经过 VMD 分解过的各个 IMF 模态分量的特征向量都不一样,这样一来每一个轴承故障都有 15 个特征向量。显然用 VMD 分解后得到的能量熵对轴承故障识别是有效的,可以保留精确的有效信息,尽可能将故障的特征表现出来,从而为输入 CNN 模型后能够快速、精确地识别出故障类别打下基础。

4.3 故障识别

将不同的故障特征向量输入到 CNN 模型进行训练,再打乱进行测试。每个故障选取 50 个样本,共计 450 个样本进行测试。测试的结果如图 12 和图 13 所示。为了体现本文方法的可行性和精确度,采用控制变量法,只改变维度,与只采取横向的、径向的、轴向的能量熵的轴承故障识别作比较,结果如表 5 所示。




图 12 训练集分类结果

表 5 不同维度提取的轴承故障识别正确率对比 %

| 维度 | 训练集正确率   | 测试集正确率   |
|----|----------|----------|
| 横向 | 93.015 9 | 92.592 6 |
| 径向 | 98.412 7 | 91.851 9 |
| 轴向 | 96.190 5 | 87.470 4 |
| 三维 | 100      | 99.259 3 |




图 13 测试集训练分类结果

根据图 12 和图 13 可知,训练集的 315 个样本全部预测正确,测试集的 135 个样本只有一个预测错误,正确率高达 99.259 3%。根据表 5 可知,单个维度,无论是横向、径向和轴向都没有三维的故障识别正确率高,足以证明本文方法的可行性。

5 结 语

对于电机轴承故障信号难提取,难以全面精确地体现出来,类型难识别等问题,很多文献要么提取定子电流信号,要么只提取一个维度的故障特征。本文则采用了三个维度的 VMD 分解故障振动信号,提取了各个维度的能量熵并输入 CNN 模型进行训练相结合的方法来完成诊断。试验结果表明,该方法采取多个维度的能量熵的提取方式可以更加全面、精确地体现故障的特征,使故障诊断的正确率大大提高。

【参考文献】

[ 1 ] 唐贵基,庞彬. ITT 变换在风电机组滚动轴承故障诊断中的应用[J]. 电力自动化设备,2017,37(9): 83.

[ 2 ] 谢国民,佟莹,陆文斌. 小波在采煤机异步电动机故障诊断中的应用[J]. 控制工程,2013,20(4): 711.

[ 3 ] 赵小惠,张梦洋,石杨斌,等. 改进 CEEMDAN 算法的电机轴承振动信号降噪分析[J]. 电子测量与仪器学报,2020,34(12):159.

[ 4 ] 吴守军,冯辅周,吴春志,等. 基于 VMD-DE 的坦克行星变速箱故障诊断方法研究[J]. 振动与冲击,2020,39(10): 170.

[ 5 ] 咎涛,庞兆亮,王民,等. 基于 VMD 的滚动轴承早期故障诊断方法[J]. 北京工业大学学报,2019,45(2): 103.

- [6] 钟志贤,焦博隆,王家园,等. 基于 VMD 和 AR 模型的转子裂纹故障诊断方法[J]. 机械强度, 2020, 42(3): 516.
- [7] 赵光权,姜泽东,胡聪,等. 基于小波包能量熵和 DBN 的轴承故障诊断[J]. 电子测量与仪器学报, 2019, 33(2): 32.
- [8] 王付广,李伟,郑近德,等. 基于多频率尺度模糊熵和 ELM 的滚动轴承剩余寿命预测[J]. 噪声与振动控制, 2018, 38(1): 188.
- [9] 皮骏,马圣,贺嘉诚,等. 基于 IGA-ELM 网络的滚动轴承故障诊断[J]. 航空学报, 2018, 39(9): 233.
- [10] 田勇,董国贵. 基于轻量级 CNN 的电机轴承故障诊断研究[J]. 齐齐哈尔大学学报(自然科学版), 2022, 38(1): 11.
- [11] 唐贵基,王晓龙. 参数优化变分模态分解方法在滚动轴承早期故障诊断中的应用[J]. 西安交通大学学报, 2015, 49(5): 73.
- [12] YANG Z, KONG C, WANG Y, et al. Fault diagnosis of mine asynchronous motor based on MEEMD energy entropy and ANN [J]. Computers and Electrical Engineering, 2021, 92: 107070.
- [13] LIN S L. Application of machine learning to a medium gaussian support vector machine in the diagnosis of motor bearing faults[J]. Electronics, 2021, 10(18): 2266.
- [14] 戴连铭,李春华. 基于小波包能量熵与 SVM 的微电网故障诊断[J]. 计算机与数字工程, 2021, 49(10): 2126.
- [15] 罗丹. 基于 ReliefF-RF 的刀具磨损状态识别方法[J]. 信息技术与信息化, 2021(8): 102.
- [16] 李奕江,张金萍,李允公. 基于 VMD-HMM 的滚动轴承磨损状态识别[J]. 振动与冲击, 2018, 37(21): 61.
- [17] 靳行,林建辉,伍川辉,等. 基于 EEMD-TEO 熵的高速列车轴承故障诊断方法[J]. 西南交通大学学报, 2018, 53(2): 359.

## 声 明

本刊已许可万方数据、重庆维普、中国学术期刊(光盘版)电子杂志社、北京世纪超星信息技术发展有限责任公司在其网站及其系列数据库产品中以数字化方式复制、汇编、发行、信息网

络传播本刊全文。该社著作权使用费与本刊相关费用抵消。如作者不同意文章被收录,请在来稿时向本刊声明,本刊将做适当处理。

《电机与控制应用》编辑部

## [ 主要栏目 ]

- |              |           |             |
|--------------|-----------|-------------|
| · 控制与应用技术    | · 研究与设计   | · 故障诊断与保护   |
| · 新能源发电与局域电网 | · 新能源汽车技术 | · 发电机组及其控制  |
| · 测试技术与测控系统  | · 材料与工艺   | · 电机生产及质量管理 |
| · 电力电子变流器技术  | · 智能制造    | · 节能应用      |
| · 实用技术成果     |           |             |