

文章编号: 2095-2163(2023)08-0209-05

中图分类号: TP391

文献标志码: A

# 轴承故障诊断特征提取方法研究

李志伟, 曹乐

(上海工程技术大学 电子电气工程学院, 上海 201620)

**摘要:** 针对轴承故障特征难以提取和分类的问题, 提出了基于经验模态分解(EMD)和支持向量机(SVM)的故障诊断分类方法。首先利用 EMD 将原始信号进行分解, 得到若干个固有模态函数(IMF)分量, 选取前 6 个固有模态函数的能量值作为输入特征向量, 利用 SVM 多故障分类器对滚动轴承正常、滚珠故障、内圈故障、外圈故障四种状态进行诊断识别。实验表明, 基于 EMD 和 SVM 的故障诊断方法可对轴承故障进行特征提取并有效识别轴承典型故障类型, 实现轴承故障诊断分类。

**关键词:** 经验模态分解; 特征提取; 支持向量机; 故障诊断

## Research on feature extraction method of bearing fault diagnosis

LI Zhiwei, CAO Le

(School of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 201620, China)

**【Abstract】** Aiming at the problem that it is difficult to extract and classify bearing fault features, a fault diagnosis and classification method based on empirical mode decomposition (EMD) and support vector machine (SVM) is proposed. Firstly, EMD is used to decompose the original signal to obtain several intrinsic modal function (IMF) components, and the energy values of the first six intrinsic modal functions are selected as input eigenvectors. SVM multi fault classifier is used to diagnose and identify four states of rolling bearing: normal, ball fault, inner ring fault and outer ring fault. The fault diagnosis method based on EMD and SVM can extract the features of bearing faults and effectively identify the typical fault types of bearings, thus realizing the classification of bearing fault diagnosis.

**【Key words】** empirical mode decomposition; feature extraction; support vector machine; fault diagnosis

## 0 引言

随着机械设备日趋精密化、复杂化、智能化, 高精度设备零部件之间的关联性更加密切。滚动轴承作为机械设备中常用的零部件, 由于轴承长期处于工作状态, 运行条件较为恶劣, 所以轴承成为最容易出现故障的零部件之一。一旦轴承出现故障, 将导致整个设备无法使用, 甚至会引发事故, 造成人员伤亡与财产的巨大损失。因此基于轴承建立设备健康检测体系, 对其故障进行诊断具有重要意义。

轴承发生故障后, 其运行引起的振动信号是非线性、非稳定的, 常用的故障特征提取方法包括时域分析、小波变换、神经网络等。利用傅里叶变换等平稳信号处理方法的效果往往不理想; 小波变换因小波基选取困难, 无法找到相对理想的故障特征; 神经

网络方法需要大数据样本进行训练, 很难在小样本下实现故障诊断。经验模态分解作为一种时频域信号处理方法<sup>[1]</sup>, 可将非线性信号分解成一系列表征信号特征时间尺度的固有模态函数, 准确估计每个 IMF 分量的瞬时特征。刘剑生等学者<sup>[2]</sup>利用 EMD 和 BP 神经网络结合进行齿轮故障诊断, 可有效降低训练误差并减少迭代次数。钟岳等学者<sup>[3]</sup>利用 EMD 将液压系统故障信号分解成多个 IMF 分量, 然后利用奇异值分解(SVD)得到特征向量, 并通过小波分析与 Hilbert-Huang 变换获得不同的特征信号进行对比, 实验表明基于 EMD-SVD 变换的故障特征提取方法取得最佳的识别效果。陈之恒等学者<sup>[4]</sup>采用粒子群优化 BP 神经网络, 将 EMD 分解的 IMF 分量与时域特征参数结合, 共同组成特征参数矩阵, 运用主成分分析验证特征提取的有效性, 实验

**基金项目:** 国家自然科学基金(61703270)。

**作者简介:** 李志伟(1995-), 男, 硕士研究生, 主要研究方向: 控制工程; 曹乐(1986-), 男, 博士, 副教授, 硕士生导师, 主要研究方向: 惯性传感与导航定位、精密生物医疗仪器、智能控制与工业互联网。

**通讯作者:** 曹乐 Email: caole00012@163.com

**收稿日期:** 2022-09-01

表明基于 EMD 和 PSO 优化 BP 神经网络的方法有效提高了点击轴承故障的识别精度。

在机械故障诊断中,神经网络方法对故障的分类效果较好,但其所需的训练和测试样本数量较大,在实际条件下大量数据很难获取。支持向量机理论是一种基于数理统计的机器学习方法,具有较好的泛化能力和小样本的处理能力,被广泛应用于故障诊断等领域。

## 1 EMD 算法基本原理

为保证 IMF 分量具备物理意义,固有模态函数中必须保证 2 个相邻的零点之间有且只有一个极值点,这使得信号求出的瞬时频率始终保持大于 0,该种定义方法使得固有模态函数更符合实际信号特点,突破了窄带信号的壁垒<sup>[5-6]</sup>。具备物理意义的 IMF 必须满足 2 个必要条件:

(1)函数在整个时间范围内,局部极值点和过零点的数目必须相等或最多相差一个。

(2)在任意时刻点,局部最大值点所形成的包络线(上包络线)与局部最小值点所形成的包络线(下包络线)关于时间轴局部对称。

EMD 分解过程如下:

**步骤 1** 假设原始信号为  $x(t)$ , 求出  $x(t)$  的全部极值点,通过对极大值、极小值进行三次样条插值得到上下包络线。

**步骤 2** 上包络线减去下包络线求取均值,可得到原始信号  $x(t)$  的均值信号  $m(t)$ , 将  $m(t)$  从原始信号  $x(t)$  中减掉,即可得到新的信号  $h_1(t)$ 。由此推得的公式如下:

$$h_1(t) = x(t) - m(t) \quad (1)$$

**步骤 3** 通常情况下  $h_1(t)$  不是 IMF 分量,因此不断重复步骤 1 到步骤 2,直至  $h_i(t)$  满足 IMF 分量定义。即新信号不再能构成包络线或者均值信号  $m(t)$  趋于 0。由此推得的公式如下:

$$h_i(t) = h_{i-1}(t) - m(t) \quad (2)$$

可将  $h_i(t)$  视为第一个 IMF 分量  $imf_1$ 。

**步骤 4**  $x(t)$  减去  $h_i(t)$  即可得到余项  $r_i(t)$ 。由此推得的公式如下:

$$r_i(t) = x(t) - h_i(t) \quad (3)$$

**步骤 5** 余项  $r_i(t)$  重复上述步骤 1~4,直至余项  $r_i(t)$  单调。

综上,原始信号分解过程全部结束,原始信号可用分解出的所有 IMF 分量与余项之和表示<sup>[7]</sup>,即:

$$x(t) = \sum_{i=1}^k imf_k(t) + r_k(t) \quad (4)$$

## 2 SVM 算法原理

支持向量机(SVM)是一种风险最小化的最佳值折中算法<sup>[8-9]</sup>。通过寻找最优分类超平面,使得这个超平面到 2 类样本集的距离之和最大化,即分类效果最大化。支持向量机包含线性、非线性两种类型,对线性的样本集主要通过线性分割线对数据样本进行分割,保证误差最小和置信范围最小,对非线性样本主要选择合适的映射函数,将线性不可分问题转化成线性可分问题。其原理如图 1 所示。




图 1 支持向量机原理图

Fig. 1 Schematic diagram of support vector machine

假设训练样本为  $(x_1, y_1), \dots, (x_l, y_l)$ , 其中  $x \in R^n, y \in (+1, -1)$ , 通过计算分类间隔问题将最优分类面问题转化成最优化问题:即满足以下最小化函数:

$$\phi(\omega) = \frac{1}{2} \|\omega\|^2 = \frac{1}{2} (\omega^T \cdot \omega) \quad (5)$$

通过引入广义拉格朗日乘子解决此约束最优化问题:

$$L = \frac{1}{2} \|\omega\|^2 - \sum_{i=1}^l \alpha_i y_i (x_i \cdot \omega + b) + \sum_{i=1}^l \alpha_i \quad (6)$$

通过  $\alpha_i$  求解函数的极大值:

$$W(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (7)$$

最终得到线性最优分类函数:

$$f(x) = \text{sgn} \left\{ \sum_{i=1}^l y_i \alpha_i^* (x_i \cdot x) + b^* \right\} \quad (8)$$

其中,  $\omega$  为最优分隔面的权重系数;  $b^*$  为偏置;  $\alpha_i$  为拉格朗日乘子。

若样本集线性不可分,则需引用核函数代替原空间的内积,将线性不可分问题转化成线性可分问题<sup>[10]</sup>,引入松弛变量  $\xi_i \geq 0$ , 则:

$$y_i [(\omega \cdot x_i) + b] \geq 1 - \xi_i \quad i = 1, 2, \dots, l \quad (9)$$

最终得到线性最优分类函数:

$$f(x) = \text{sgn} \left\{ \sum_{i=1}^l y_i \alpha_i^* K(x_i, x) + b^* \right\} \quad (10)$$

常用的支持向量机核函数有线性核函数、多项式核函数、RBF 核函数、sigmoid 核函数, RBF 核函数具有较高的泛化性和分类准确率, 故采用 RBF 核函数。在使用 RBF 核函数的情况下, 一般需要优化的参数有:  $c$  和  $g$ 。其中,  $c$  是惩罚系数,  $g$  是 RBF 的系数,  $g$  的取值直接影响到能否找到一个可将多类数据分开的最优超平面, 因此, 在交叉验证过程中使用简单的网格算法找到最佳的  $c$  和  $g$ 。

基于 EMD 能量值分析, 结合 SVM 方法对齿轮箱故障进行特征提取和分类, 具体流程如图 2 所示。

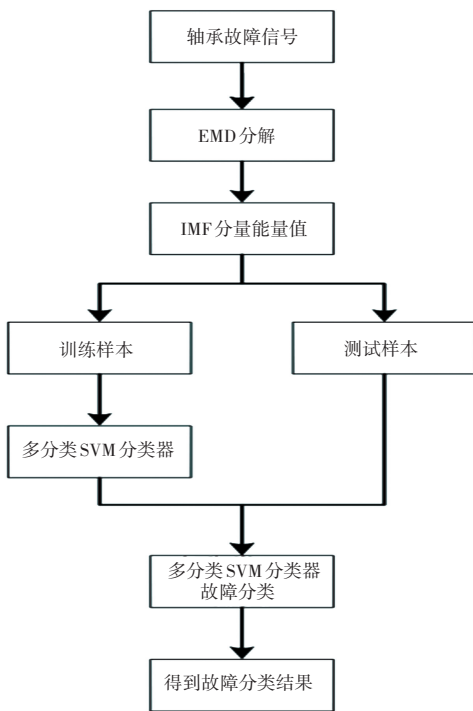


图 2 滚动轴承故障诊断流程图

Fig. 2 Flow chart of rolling bearing fault diagnosis

### 3 基于 EMD 能量值和 SVM 的故障诊断方法

#### 3.1 振动信号采集

本文采用的是人工预先设置故障的试验方案。对智能小车平台驱动轴轴承进行加工处理, 模拟正常、滚珠故障、内圈故障、外圈故障, 将预先设置故障的轴承安装到智能小车的驱动轴进行测试, 采集驱动轴轴承的振动信号数据。智能小车驱动轴轴承型号为 Z1029, 尺寸为 12 mm×32 mm×10 mm, 单列滚动体, 使用人工预先设置故障模拟故障类型, 采样频

率为 1.6 kHz, 电机负载 (HP) 为 0。对故障信号进行采集, 运行 5 min 后得到 48 万个有效数据, 将 48 万个数据分成 100 份, 前 80 组数据用于训练, 后 20 组数据用于测试。总共模拟 4 种典型故障类型, 包括正常、滚珠故障、内圈故障和外圈故障, 如图 3 所示。




图 3 4 种典型故障

Fig. 3 Four typical faults

#### 3.2 EMD 特征提取

利用经验模态分解将正常信号、滚珠故障、内圈故障、外圈故障信号进行分解, 得到各个 IMF 分量。

研究后得到的正常信号 IMF 分量如图 4 所示, 滚珠故障信号 IMF 分量如图 5 所示, 内圈故障信号 IMF 分量如图 6 所示, 外圈故障信号 IMF 分量如图 7 所示。




图 4 正常信号 IMF 分量图

Fig. 4 IMF component diagram of normal signal

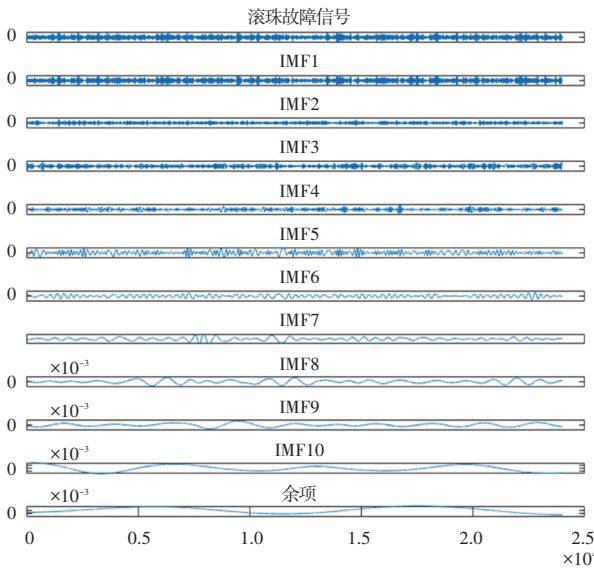


图 5 滚珠故障信号 IMF 分量图

Fig. 5 IMF component diagram of ball fault signal

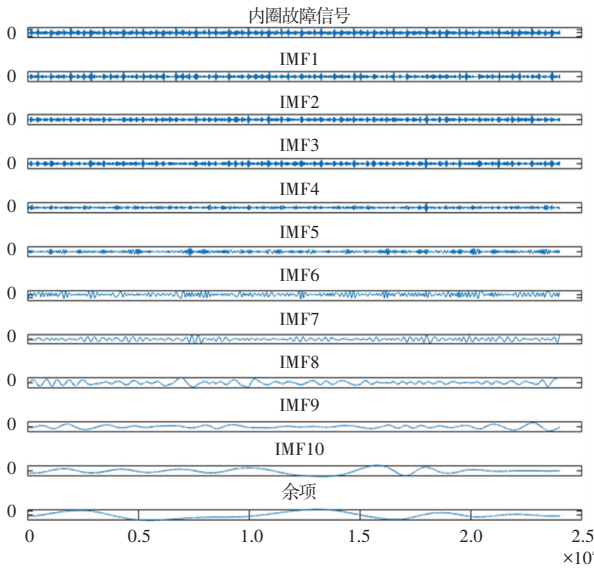


图 6 内圈故障信号 IMF 分量图

Fig. 6 IMF component diagram of inner ring fault signal




图 7 外圈故障信号 IMF 分量图

Fig. 7 IMF component diagram of outer ring fault signal




图 8 基于 EMD-SVM 故障分类结果

Fig. 8 Fault classification results based on EMD-SVM

表 1 各诊断方法的故障识别率

Tab. 1 Fault identification rate of each diagnosis method %

| 故障类型    | 正常  | 滚珠 | 内圈 | 外圈 |
|---------|-----|----|----|----|
| 分类准确率/% | 100 | 90 | 90 | 95 |

由图 4~图 7 可知,EMD 将信号分解成多个 IMF 分量和余项,不同的 IMF 分量表征不同的时间特征尺度,从第一个 IMF 分量开始频率逐渐降低,直至余项单调。通常情况下,信号的重要信息与特征集中于高频段,另外也可以看出不同故障类型的 IMF 分量显然是不同的。综上,可将前 6 个 IMF 分量的能量值信息作为特征值。

### 3.3 SVM 分类

基于经验模态分解后的 IMF 分量的能量值作为特征向量训练,选取 4 种状态的 80 组数据进行训练,分类结果如图 8 所示。各诊断方法得到的故障识别率见表 1。

### 4 结束语

故障诊断技术是一门交叉性学科,近年来在航天、化工、石油和工程机械等领域发挥着越来越重要的作用。滚动轴承故障检测一直是机械设备领域亟需解决的热点课题。本文通过人工模拟滚动轴承故

障类型,模拟正常、滚珠故障、内圈故障、外圈故障,将预先设置故障的轴承安装到智能小车的驱动轴进行测试,采集驱动轴轴承的振动信号数据,该方法先将不同故障类型的时域振动信号进行 EMD 分解,再提取训练样本数据中不同维数的能量作为特征向量、选用径向基核函数方法建立 SVM 模型,最后对测试样本数据中的特征向量进行故障识别。试验结果表明,在本文中人工模拟滚动轴承故障类型经过 EMD-SVM 分类后平均分类准确率达到 93.75%,能够准确识别轴承的不同故障类型,为轴承的早期故障提供参考。

## 参考文献

- [1] 郭志超,朱敏,王荟荟. EMD-SVM 结合对风机齿轮箱振动检测与故障诊断[J]. 郑州师范教育,2020,9(04):6-9.
- [2] 刘剑生,王细洋. 基于 EMD 与 BP 神经网络的齿轮故障诊断

- [J]. 失效分析与预防,2020,15(06):370-375,392.
- [3] 钟岳,王钊,方虎生,等. 基于 EMD-SVD 的液压系统故障模糊聚类研究[J]. 机电工程技术,2020,49(11):104-108.
- [4] 陈之恒,宋冬利,张卫华,等. 基于 EMD 及改进 PSO\_BP 的电机轴承故障诊断[J]. 测控技术,2020,39(11):33-38,125.
- [5] 唐静,王二化,朱俊,等. 基于 EMD 和 SVM 的齿轮裂纹故障诊断研究[J]. 机床与液压,2020,48(14):200-204.
- [6] 贺志晶,王兴,李凯,等. 基于 FIR-EMD 和改进 SVM 的铁路轴承故障诊断[J]. 噪声与振动控制,2017,37(02):143-147.
- [7] 彭松,黄志辉,胡奇宇. 基于 EMD 与 SVM 的地铁列车滚动轴承故障诊断方法分析[J]. 科技创新与应用,2016(23):36.
- [8] VAPNIK V. Nature of statistical learning theory [M]. US: Springer Science & Business Media,1999.
- [9] 王红军,徐小力. 支持向量机在设备故障诊断方面的应用研究概述[J]. 机械设计与制造,2005(09):157-159.
- [10] 马玉猛. 基于 EMD 和 PSO-SVM 的通用航空飞机燃油流量预测[J]. 滨州学院学报,2022,38(04):20-24.
- [11] 陈炳光. 基于 EMD 和 SVM 煤矿通风机轴承故障诊断的研究[D]. 徐州:中国矿业大学,2018.

(上接第 208 页)

## 5 结束语

本文针对赛道识别问题,提出了一种基于 UNet 模型的赛道识别方法,使用 UNet 模型分割后的掩码图像提取赛道的边缘信息,再用细化算法求取中点集。本文对 UNet 模型的框架和原理进行了简单阐述,并通过时效性分析,发现了模型存在的初始运行慢问题,通过准确度分析实验,发现相比于传统赛道识别方法,本文方法在不同环境下的赛道识别有了很大的提升。后续需要继续研究结构和算法的改进,进一步提升新方法的时效性和准确率。

## 参考文献

- [1] 黄俊嘉,余志贤,陈锐,等. 基于特征分类的智能汽车赛道元素识别算法[J]. 计算机产品与流通,2018(03):127,129.

- [2] 吴绪辉,潘璇峰,邓伟杰. 基于图像分割匹配的赛道元素识别算法[J]. 物联网技术,2019,9(11):25-27.
- [3] 俞洋,李峰,缪奕扬. 基于机器视觉的全元素赛道智能小车实验系统设计与应用[J]. 中南民族大学学报(自然科学版),2022,41(06):689-696.
- [4] 柴志忠. 基于深度卷积神经网络的病理影像研究[D]. 厦门:厦门大学,2019.
- [5] 王宁. 基于改进 YOLO 网络与极限学习机的绝缘子故障检测[D]. 大庆:东北石油大学,2021.
- [6] 韩俊文. 基于 OpenCV3 的焊缝轨迹识别系统[J]. 电子技术与软件工程,2018(18):43-44.
- [7] 徐奎奎. 基于深度学习的合金组织缺陷检测及应用研究[D]. 石家庄:河北经贸大学,2022.
- [8] 姜萍萍,颜国正,丁国清,等. 一种便携式工业视频内窥镜的开发[J]. 光学精密工程,2002(04):407-410.
- [9] 汪欢. 无源毫米波图像序列超分辨重建算法研究[D]. 成都:电子科技大学,2014.
- [10] 李易. 多类型车道路线的检测与识别方法研究[D]. 西安:西安石油大学,2021.