

# 基于 MFDE-SVM 算法的轴承故障诊断研究

陈鑫洋 李水明 肖振泉

(柳州铁道职业技术学院 广西 柳州 545616)

**摘要:** 针对旋转机械设备轴承故障信号难以识别的问题, 提出了一种基于多尺度涨落色散熵的支持向量机算法 (MFDE-SVM)。多尺度涨落色散熵 (MFDE) 通过分析不同时间尺度下的数据变化, 来捕捉数据的多样性和不规则性, 提取隐藏在轴承振动信号中的故障特征, 以此提高支持向量机 (SVM) 在故障诊断中分类的准确性。实验结果表明, MFDE-SVM 算法分类精准度高达 99.36%, 相对于 MDE、MFE 和 MSE 算法故障识别精准度提高了 3.83%、5.96% 和 5.75%。

**关键词:** 故障诊断; 支持向量机; 轴承; 多尺度涨落色散熵

## 0 引言

随着工业的快速发展, 旋转机械设备在各个领域拥有举足轻重的地位。轴承作为旋转机械设备中不可或缺但极易损坏的部件, 如果能在其损坏早期及时发现, 可以避免因轴承失效而造成的重大安全事故<sup>[1]</sup>。因此, 如何准确地提取出隐藏在轴承信号中的故障特征, 已成为国内外机械设备故障诊断的研究热点。

徐乐等<sup>[2]</sup>针对小样本故障信息特征难以识别的问题, 提出了一种新颖的故障诊断算法, 通过局部均值分解算法 (LMD) 来对轴承振动信号进行特征提取, 并根据振动信号在不同频域曲线的特性不同, 来对旋转机械设备进行故障诊断。李卫民等<sup>[3]</sup>提出了一种近似熵与支持向量机相结合的算法, 来对异步电机故障信号进行故障诊断, 通过近似熵算法建立故障特征数据集, 并使用支持向量机来对其进行诊断分类。Zhao 等<sup>[4]</sup>分析了粗粒化过程中数据频率特性变化, 提出了一种新的非线性动态方法 - 并行多尺度熵算法。通过实验结果表明, 所提出的并行多尺度熵比原算法具有更好的辨别性和稳定性, 可以为故障诊断提供更优的特征向量。Ju 等<sup>[5]</sup>提出了一种用于滚动轴承故障诊断的改进多尺度熵 (IMSE) 特征提取方法。使用 IMSE 提取不同条件下的轴承特征, 并通过支持向量机分类器对其进行识别。

本文为了提高旋转机械设备的故障振动信号的辨别精度, 提出了一种基于多尺度涨落色散熵的支持向量机算法 (MFDE-SVM), 通过多尺度涨落色散

熵, 来捕捉轴承故障信号中的微小涨落并构建故障特征数据集, 以此来提高 SVM 算法的故障识别率, 并通过实验证明了 MFDE-SVM 算法在故障诊断中的有效性。

## 1 多尺度涨落色散熵

多尺度涨落色散熵 (Multiscale Fluctuation Dispersion Entropy, MFDE) 是一种用于分析信号或时间序列复杂性的数学工具, 它结合了多尺度分析和色散熵的概念, 可以更好地描述信号中的涨落和不规则性, 具体步骤如下<sup>[6]</sup>。

(1) 将原始信号  $X$  划分为  $l$  长度的信号片段。其中,  $l$  为 MFDE 算法的尺度因子。通过计算信号片段中的平均值, 得到粗粒化时间序列  $y^{(l)} = \{y_j^{(l)}\}$ 。

$$y_j^{(l)} = \frac{1}{l} \sum_{i=(j-1)l+1}^j x_i, \quad 1 \leq j \leq [N/l] \quad (1)$$

式 (1) 中, 若  $l=1$ , 则时间序列为原始信号;  $[N/l]$  为  $\text{round}([N/l])$ 。

(2) 通过正态分布的方式将式 (1) 得到的时间序列映射到  $Y^{(l)} = \{y_j^{(l)}, j=1, 2, \dots, N/l\}$ 。

$$y_j^{(l)} = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^{y_j^{(l)}} e^{-\frac{(t-\mu)^2}{2\sigma^2}} dt \quad (2)$$

式中:  $y_j^{(l)} - 0 \sim 1$  之间的任意整数;

$\mu - y(l)$  的均值;

$\sigma - y(l)$  的标准差。

(3) 将  $Y(l)$  通过线性变化映射到索引  $z^{(e)} = \{z_j^{(e)}\}$ 。

$$z_j^{(c)} = R(c \cdot y_j^{(l)} + 0.5) \quad (3)$$

式中： $c$  - 类别；

$R(\cdot)$  - 取整函数。

(4) 通过重构相空间的方法得到重构之后的时间序列  $z^{(m,c)} = \{z_i^{(m,c)}\}$ 。

$$z^{(m,c)} = \{z_i^{(c)}, z_{i+t}^{(c)}, \dots, z_{i+(m-1)t}^{(c)}\}, i=1, 2, \dots, (N/l) - (m-1)t \quad (4)$$

式中： $t$  - MFDE 算法的时延；

$m$  - MFDE 算法的维度。

(5) 对于重构之后的时间序列进行色散分析。

$$z_i^{(m,c)} = \{z_{i+t}^{(c)} - z_i^{(c)}, z_{i+2t}^{(c)} - z_{i+t}^{(c)}, \dots, z_{i+(m-1)t}^{(c)} - z_{i+(m-2)t}^{(c)}\}, \quad (5)$$

$i=1, 2, \dots, (N/l) - (m-1)t$

(6) 计算色散模式的相对频率  $p^{(s)}(\pi'_{g'_1 g'_2 \dots g'_m})$ 。

$$p^{(s)}(\pi'_{g'_1 g'_2 \dots g'_m}) = \frac{1}{(N/l) - (m-1)t} \text{Number}\{i | i \leq (N/l) - (m-1)t\} \quad (6)$$

式中： $(\pi'_{g'_1 g'_2 \dots g'_m})$  - MFDE 算法的色散模式。

(7) MFDE 算法的表达式：

$$MFDE(X, c, n, t, l) = \sum_{\pi=1}^{(2c-1)^{m-1}} p^{(s)}(\pi'_{g'_1 g'_2 \dots g'_m}) \cdot \ln p^{(s)}(\pi'_{g'_1 g'_2 \dots g'_m}) \quad (7)$$

MFDE 算法在故障诊断领域具有重要作用，多尺度涨落色散熵能够同时考虑不同时间尺度上的信号特征，可以更全面地描述信号的复杂性，并且能够捕捉故障信号中的微小涨落，这些涨落是轴承故障的早期迹象。因此本文选用 MFDE 算法对电机轴承故障信号进行特征提取，多尺度涨落色散熵流程图如图 1 所示。

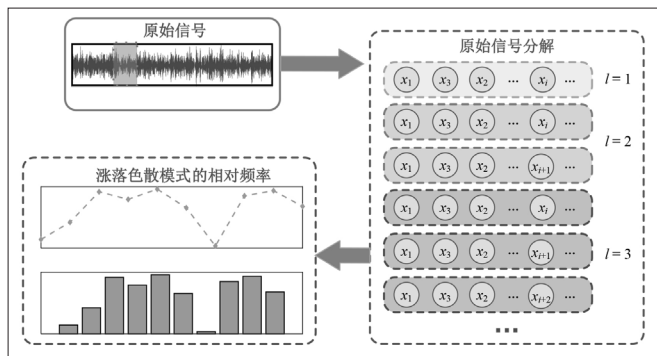


图 1 多尺度涨落色散熵流程图

## 2 故障信号特征提取实验验证

为验证多尺度涨落色散熵在故障诊断中的有效性，以凯斯西储大学电机轴承数据作为特征提取对象，并与多尺度模糊熵算法 (MFE)、多尺度样本熵算法 (MSE) 及多尺度色散熵算法 (MDE) 进行对比分析，来证明 MFDE 算法在故障诊断领域的有效性。实验对象为电机驱动端的深沟球轴承 (SKF 6025-2RS)，选取三种轴承故障类型和一种正常轴承数据作为实验的训练集和测试集，这三种故障类型分别为内圈故障 (IRF)、外圈故障 (ORF) 和滚子故障 (BF)，并且每种故障信息包含 2 种不同的故障程度。电机系统图如图 2 所示，不同算法参数表见表 1，电机轴承故障数据信息表见表 2。




图 2 电机系统图

本研究使用 MFDE 算法、MDE 算法、MFE 算法和 MSE 算法分别对表 2 的故障信息进行特征提取，并构建故障特征数据集，通过支持向量机算法 (SVM) 对构建的数据集进行分类，以此来证明 MFDE 算法在故障诊断中的有效性，其四种算法的特征提取熵均值曲线如图 3 所示。

表 1 不同算法参数表

熵方法	参数设置
MFE	$N=2000, m=2, r=0.15SD, n=2, t=1, s=25$
MSE	$N=2000, m=2, r=0.15SD, t=1, s=25$
MDE	$N=2000, m=2, t=1, s=25, c=6$
MFDE	$N=2000, m=2, t=1, s=25, c=6$

由图 3 可知，MDE 算法的特征提取中 N7 和 N5 的熵均值较为接近，N4 和 N6 的熵均值较为接近，而且当尺度因子位于 15 之后，N2 ~ N7 的熵均值曲线较为接近且不易区分；MFE 算法和 MSE 算法中

表2 电机轴承故障数据信息表

故障位置及程度	标签	训练集	测试集	样本总数	样本点
健康 (NOR-0mm)	N1	30	70	100	2000
内圈 (IRF-0.18mm)	N2	30	70	100	2000
内圈 (IRF-0.36mm)	N3	30	70	100	2000
外圈 (ORF-0.18mm)	N4	30	70	100	2000
外圈 (ORF-0.36mm)	N5	30	70	100	2000
滚子 (BF-0.18mm)	N6	30	70	100	2000
滚子 (BF-0.36mm)	N7	30	70	100	2000

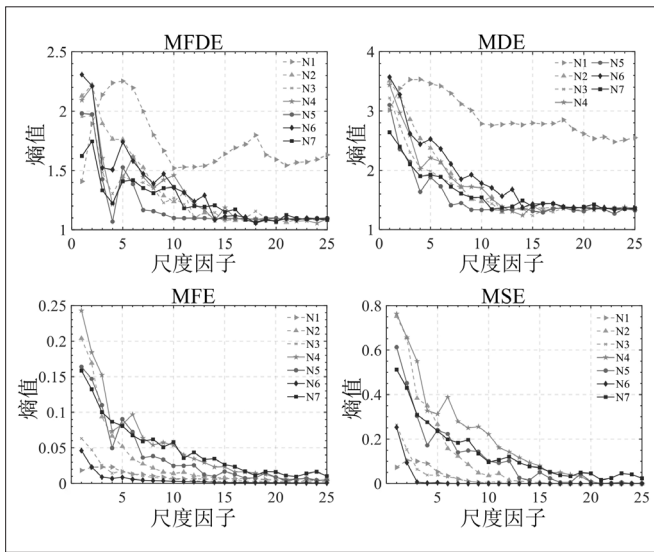


图3 熵均值曲线图

N6、N1 和 N3 的熵均值相似度很高，且整体熵均值较低不易区分；MFDE 算法虽然在尺度因子大于 15 之后，各类轴承信号的熵均值不易区分，但是在尺度因子小于 15 的区域，轴承信号的熵均值各有不同，区分度很大。

本文建立故障特征分类结果图（图 4）和故障特征分类热力图（图 5），来更为直观地展示四种算法的特征提取效果。MFDE 算法所提取的故障特征数据集，在 SVM 算法下进行故障分类，其分类错误的样本仅为 3 个，而 MDE、MFE 和 MSE 算法分类错误的样本分别为 21、31 和 30。由图 5 可知，MFDE 算法的故障识别精准度为 99.36%，而 MDE、MFE 和 MSE 算法的故障识别精准度分别为 95.53%、93.40% 和 93.61%，其故障识别精准度分别提高了 3.83%、5.96% 和 5.75%。通过故障分类结果表明，与 MDE、MFE 和 MSE 算法相比，本文所使用的 MFDE 算法可以更好地对轴承振动信号进行特征提取，以此来提高电机轴承故障的分类准确率。

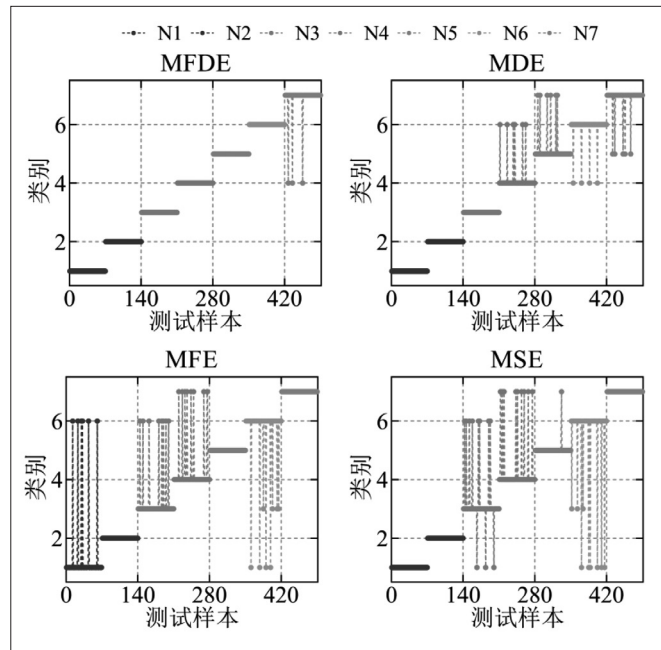


图4 故障特征分类结果

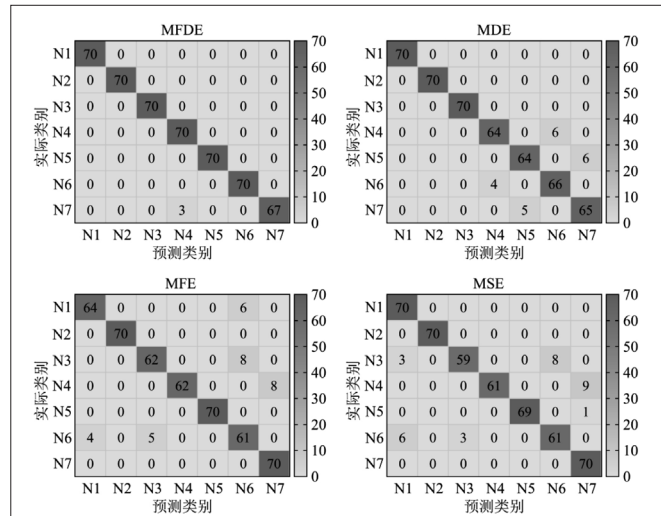


图5 故障特征分类热力图

### 3 结语

多尺度涨落色散熵对电机轴承振动数据进行特征提取时，可以考虑不同时间尺度上的信号特征，并捕捉故障信号中的微小涨落，从而全面地描述故障信号的复杂性。本研究以凯斯西储大学的电机轴承数据作为 MFDE 算法的特征提取对象，并使用支持向量机算法（SVM）对故障特征数据集进行分类，其分类精准度为 99.36%。为了进一步验证 MFDE-SVM 算法的有效性，使用 MDE、MFE 和 MSE 算法进行对比分析，结果表明 MFDE-SVM 算法的精准度均高于其他三种算法。



**基金项目：**柳州铁道职业技术学院科研项目“基于人工智能的农业生产环境预警系统研究及应用”（2020-KJA05）；2021年度广西高校中青年教师科研基础能力提升项目“智能电机轴承故障监测系统研究”（2021KY1405）；2020年广西高等学校千名中青年骨干教师培育计划项目（项目批准号：桂教教师[2020]58号）。

### 参考文献：

- [1] 张琛, 赵荣珍, 邓林峰. 基于 EEMD 奇异值熵的滚动轴承故障诊断方法 [J]. 振动. 测试与诊断, 2019, 39(2): 353-358+446-447.
- [2] 徐乐, 李伟, 张博, 等. 基于 LMD 能量熵的齿轮箱故障诊断研究 [J]. 机械传动, 2022, 46(10): 24-29.
- [3] 李卫民, 马继召, 雷晓柱. 基于近似熵与支持向量机的异步电机故障诊断研究 [J]. 机床与液压, 2021, 49(5): 173-

176+155.

[4] Zhao D, Liu S, Cheng S, et al. Parallel multi-scale entropy and it's application in rolling bearing fault diagnosis [J]. Measurement, 2021, 168(1): 108333.

[5] Ju B, Zhang H, Liu Y, et al. A feature extraction method using improved multi-scale entropy for rolling bearing fault diagnosis [J]. Entropy, 2018, 20(4): 212.

[6] 徐哲熙, 刘婷, 任晟民, 等. 基于时移多尺度波动散布熵和改进核极限学习机的水电机组故障诊断 [J]. 工程科学与技术, 2023(6): 1-13.

**作者简介：**陈鑫洋（1987.06-），男，汉族，广西桂林人，硕士研究生，副教授，研究方向：智能控制及其应用；李水明（1983.03-），男，汉族，广东湛江人，硕士研究生，副教授，研究方向：机电一体化技术及其应用；肖振泉（1990.11-），男，汉族，广西柳州人，硕士研究生，讲师，研究方向：机械制造及自动化。

