

基于 CEEMDAN-SVD 和 CNN 的轴承故障识别



张丽艳^{1,*}, 王振宇¹, 李林²

¹大连交通大学计算机与通信工程学院电子与通信工程系, 辽宁大连 116028

²大连交通大学机械工程学院机械电子系, 辽宁大连 116028

摘要: 轴承是电机的核心组件, 轴承工作时往往要高速旋转, 极易产生磨损和疲劳。滚动轴承出现故障会导致设备停机、生产延误和维修成本增加。滚动轴承的故障诊断已成为确保电机系统安全性、效率和可用性的关键。滚动轴承故障诊断通常对其振动信号进行处理、分析做出判断, 本文使用完全集合经验模态分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, CEEMAND)、奇异值分解、Renyi 熵和卷积神经网络对轴承振动信号进行处理进而进行故障诊断。滚动轴承振动信号经过 CEEMDAN 分解后得到的本征模态函数 (Intrinsic Mode Function, IMF) 分量存在无法描述特征信息的虚假分量, 所以根据计算原始信号与各 IMF 分量的相关系数, 筛选出较高相关系数的 IMF 分量, 并对筛选出来的较高相关系数的 IMF 分量进行奇异值分解得到其奇异值, 再计算奇异值的 Renyi 熵以组成故障特征向量。最后将故障特征向量输入到卷积神经网络 (Convolutional Neural Network, CNN) 进行故障类别的识别。当训练集比例占 20% 时, 别准确率为 99.3%。故障信号检测准确率为 100%, 表明本文方法有很好的故障识别效果。

关键词: 故障识别; 奇异值分解; 完全集合经验模态分解; 卷积神经网络

DOI: [10.57237/j.mse.2024.01.002](https://doi.org/10.57237/j.mse.2024.01.002)

Bearing Fault Identification Based on CEEMDAN-SVD and CNN

Zhang Liyan^{1,*}, Wang Zhenyu¹, Li Lin²

¹Department of Electronic and Communication Engineering, School of Computer and Communication Engineering, Dalian Jiaotong University, Dalian 116028, China

²Department of Mechanical Electronics, School of Mechanical Engineering, Dalian Jiaotong University, Dalian 116028, China

Abstract: Bearings are the core components of motors, and they often rotate at high speeds during operation, which can easily cause wear and fatigue. The failure of rolling bearings can lead to equipment downtime, production delays, and increased maintenance costs. The fault diagnosis of rolling bearings has become the key to ensuring the safety, efficiency, and availability of motor systems. Fault diagnosis of rolling bearings usually involves processing and analyzing their vibration signals to make judgments. In this paper, Complete Ensemble Empirical Mode Decomposition (CEEMAND), Singular Value Decomposition, Renyi Entropy, and Convolutional Neural Networks are used to process the bearing

基金项目: 大连市重点科技研发计划项目 (2022YF11GX008).

*通信作者: 张丽艳, zhangliyan@126.com

收稿日期: 2023-11-30; 接受日期: 2023-12-28; 在线出版日期: 2024-01-20

<http://www.mechscieng.com>

vibration signals for fault diagnosis. The intrinsic mode function (IMF) components obtained from the vibration signal of rolling bearings after CEEMDAN decomposition contain false components that cannot describe the characteristic information. Therefore, based on the calculation of the correlation coefficients between the original signal and each IMF component, IMF components with higher correlation coefficients are selected, and singular value decomposition is performed on the selected IMF components with higher correlation coefficients to obtain their singular values. Calculate the Renyi entropy of the singular value again to form the fault feature vector. Finally, the fault feature vector is input into a Convolutional Neural Network (CNN) for fault category recognition. When the training set accounts for 20%, the accuracy rate is 99.3%. The accuracy of fault signal detection is 100%, indicating that the method proposed in this paper has good fault recognition performance.

Keywords: Fault Identification; Singular Value Decomposition; Complete set Empirical Mode Decomposition; Convolutional Neural Network

1 引言

轴承是电机的核心组件，在电机运行时，轴承往往要保持高速旋转，极易产生磨损和疲劳。滚动轴承承载和传递旋转运动，同时承受高速、高温和高负荷等复杂工况。因此滚动轴承较其他硬件相比更容易出现故障，导致设备停机、生产延误和维修成本增加。滚动轴承的故障诊断已成为确保电机系统安全性、效率和可用性的关键措施[1]。在常规的故障检测方法中，主要是由专家根据自身的专业知识，通过信息分析等方法来对电动机的运行状态进行常规检测，很难做到对电动机的实时准确检测。如何高效地实现轴承的故障检测，是目前的一个热门课题[2-5]。肖俊青等[6]提出了一种自适应白噪声平均总体经验模态分解，模糊熵与卷积神经网络结合的故障诊断方法。苏文胜等[7]提出了将 EMD 降噪和谱峭度法结合的滚动轴承故障检测方法。杨杰[8]将能量熵和 EEMD 结合对低速轴承故障进行诊断。本文给出了一种基于 CEEMDAN、奇异值分解、Renyi 熵和卷积神经网络的故障识别方法。

2 算法基本原理

2.1 完全集合经验模态分解

CEEMDAN 是对 EEMD 方法的改进，CEEMDAN 综合了 EEMD 和自适应噪声方法，以提高信号分解和去噪的效果。CEEMDAN 有效解决了 EMD 的模态混叠现象和 EEMD 的分解完备性不佳问题[9, 10]。CEEMDAN 在信号分解前添加一个特定的噪声，然后分解得到每一个模态，用 \overline{IMF}_k 表示第 k 阶模态， $x[n]$ 为原始信号，由式(1)计算得到第一个残余量 $r_1[n]$:

$$r_1[n] = x[n] - \overline{IMF}_1[n] \quad (1)$$

CEEMDAN 算法[5]的过程为：

Step 1 对 $x[n] + \varepsilon_0 w^i[n]$ 进行 EMD 分解和总体平均，获得第一阶模态分量 $\overline{IMF}_1[n]$:

$$\overline{IMF}_1[n] = \frac{1}{I} \sum_{i=1}^I IMF_1^i[n] = IMF_1[n] \quad (2)$$

Step 2 计算第一个残余量，如式(1):

$$r_1[n] = x[n] - \overline{IMF}_1[n] \quad (3)$$

Step 3 对 $r_1[n] + \varepsilon_1 E_1(w^i[n])$, $i = 1, \dots, I$ 进行分解和总体平均，定义第二阶模态分量 $\overline{IMF}_2[n]$:

$$\overline{IMF}_2[n] = \frac{1}{I} \sum_{i=1}^I E_1(r_1[n] + \varepsilon_1 E_1(w^i[n])) \quad (4)$$

Step 4 对 $k = 2, \dots, K$ 计算 k 个残余量:

$$r_k[n] = r_{(k-1)}[n] - \overline{IMF}_k[n] \quad (5)$$

Step 5 分 $r_k[n] + \varepsilon_k E_k(w^i[n])$, $i = 1, \dots, I$ ，并定义第 $k+1$ 阶模态分量 $\overline{IMF}_{(k+1)}[n]$:

$$\overline{IMF}_{(k+1)}[n] = \frac{1}{I} \sum_{i=1}^I E_k(r_k[n] + \varepsilon_k E_k(w^i[n])) \quad (6)$$

Step 6 重复 step 4、step 5，直到获得的残余量不满足至少有两个极值，分解结束。最后一个残余量:

$$R[n] = x[n] - \sum_{k=1}^K \overline{IMF}_k \quad (7)$$

其中， K 为获得的模态总数，因此原始信号 $x[n]$ 可以表达为:

$$x[n] = \sum_{k=1}^K \overline{IMF_k} + R[n] \quad (8)$$

2.2 奇异值分解

奇异值分解在数据分析、信号处理和机器学习等领域发挥着重要作用，奇异值分解得到的奇异值具有稳定性和不变性，可以较好的反映原始信号的内在特征[11, 12]，基本原理如下：设秩为 r 的实矩阵 $A \in R^{m \times n}$ ，则矩阵 A 可分解为：

$$A = USV^T = \sigma_1 u_1 v_1 + \sigma_2 u_2 v_2 + \cdots + \sigma_k u_k v_k \quad (9)$$

其中，矩阵 V 称为右奇异矩阵；矩阵 U 称为左奇异矩阵；矩阵 $S \in R^{m \times n}$ 称为奇异值矩阵，其表达式为：

$$S = \begin{bmatrix} S_1 & 0 \\ 0 & 0 \end{bmatrix} \quad (10)$$

$$S_1 = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_k) \quad (11)$$

$$k = \text{Rank}(A) < p = \min(m, n) \quad (12)$$

$$\sigma_1 \geq \sigma_2 \geq \cdots \geq \sigma_k \geq 0 \quad (13)$$

式中 0 为零矩阵。

2.3 Renyi 熵

一个离散随机变量 $X = \{x_k \mid k = 1, 2, \dots, n\}$ ，Renyi 熵定义为

$$R_\alpha(X) = \frac{1}{1-\alpha} \sum_{i=1}^n \log p_k^\alpha \quad (14)$$

式(14)中， p_k 为事件 $X = x_k$ 的概率密度， $\sum_{k=1}^n p_k = 1$ ； $\alpha \geq 0$ ，表示 Renyi 熵的阶数。在信息论中，Renyi 熵与 Shannon 熵一样，可以反映出信号的信息量和复杂度[13, 14]。Renyi 熵在信息理论、统计学、机器学习和物理学等领域有广泛应用。不同的 α 值对应不同的熵量度。当 α 趋近于1时，Renyi 熵退化为 Shannon 熵。通过参数 α 的调整，可以获得不同的熵量度，对于不同领域的问题分析和建模提供了更多的灵活性和适应性。

2.4 卷积神经网络

卷积神经网络是具有独特结构的神经网络，可以有效降低网络中的参数量，防止出现过拟合现象[15]。卷积神经网络主要包括卷积层、池化层，经过卷积层的卷积运算后要用激活函数进行非线性变化，还需要用损失函数进行分类任务的损失计算。

2.4.1 卷积层

卷积层中使用卷积核对输入信号或图像进行卷积操作，但因为卷积每次只针对输入信号或图像的局部区域，所以卷积核还要以一定的步长遍历整个信号或图像。一维卷积的计算公式为：

$$y^{l(i,j)} = K_i^l * X^{l(rj)} = \sum_{j=0}^{W-1} K_i^{l(j)} X^{l(j+rj)} \quad (15)$$

其中 $*$ 表示卷积操作， K_i^l 表示第 l 层中第 i 个卷积核的第 j 个权值， $X^{l(rj)}$ 表示第 l 层中第 j 个被卷积的局部区域， W 表示卷积核的宽度。

2.4.2 激活函数

经过卷积运算之后的结果还需要使用激活函数进行非线性变化，增强特征的线性可分性。常见的激活函数有 Sigmoid 函数、Relu 函数和 Tanh 函数，分别如公式(16)、(17)、(18)所示。在训练的过程中，Tanh 函数与 Sigmoid 函数都会出现梯度消失的问题，而 Relu 函数可以很好地克服梯度消失的问题[16]。

$$f(x) = \text{Sigmoid}(x) = \frac{1}{1+e^{-x}} \quad (16)$$

$$f(x) = \text{Tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (17)$$

$$f(x) = \text{ReLU}(x) = \max(0, x) \quad (18)$$

此外在多分类问题中输出层一般使用 Softmax 函数对输入的特征进行分类。Softmax 函数的表达式如公式(19)所示。

$$f(x) = \text{softmax}(z^0(j)) = \frac{e^{z^0(j)}}{\sum_{k=1}^M e^{z^0(k)}} \quad (19)$$

其中 $z^0(j)$ 表示第 j 个神经元在输出层的特征值， M 表示类别总数。

2.4.3 池化层

池化层是对卷积层提取的特征进行下采样，减少神经网络的参数量加快处理速度，防止因参数过多而出现过拟合现象。池化层能够有效减小矩阵长度和维度，并且减少在全连接层上的参数。池化层具有和卷积层相似的传递流程，都必须由人工规定滑动窗口矩阵的方向和步长。池化操作的过程与卷积操作类似，通过池化窗口以一定的步长对特征图进行遍历，在池化窗口内采用不同的统计方法作为该局部区域的下采样值。常用池化方法有平均池化和最大值池化，表达

式分别如式(20)、(21)所示。

$$p^{l(i,t)} = \frac{1}{w} \sum_{t=(j-1)w+1}^{jw} a^{l(i,t)} \quad (20)$$

$$p^{l(i,t)} = \max_{(j-1)w+1 \leq t \leq jw} \{a^{l(i,t)}\} \quad (21)$$

其中 $p^{l(i,t)}$ 表示池化区域的宽度, $a^{l(i,t)}$ 表示第 l 层第 i 帧第 t 个神经元的激活值, w 表示池化区域的宽度。

2.4.4 损失函数

在多分类问题中交叉熵损失函数能够反映真实概率分布与预测概率分布之间的差异, 而且如果交叉熵的数值越低, 则表明该模型的分类表现越好。通常会与 Softmax 函数搭配进行分类任务的损失计算。交叉熵函数的公式如(22)所示。

$$L = -\frac{1}{m} \sum_{k=1}^m \sum_j p_k^j \log q_k^j \quad (22)$$

其中 m 表示输入批量的大小, p_k^j 表示目标分布的真实值, q_k^j 表示神经网络实际输出的 Softmax 的值, 当目标类别为 j 时 $p^j = 1$, 否则 $p^j = 0$ 。

3 本文故障诊断流程

本文利用 CEEMDAN 和 SVD 方法在信号处理中的优点, 将 CEEMDAN-SVD 模式和 CNN 相结合实现故障诊断。如图 1 所示, 该方法使用 CEEMDAN 对轴承信号进行分解得到一系列 IMF 分量, 利用相关系数剔除相关性较低的虚假分量, 将含有丰富故障信息的 IMF 分量作为初始特征向量矩阵, 基于此矩阵进行 SVD 分解获得奇异值, 再计算奇异值的 Renyi 熵作为特征参数以此构造特征向量。最后建立 CNN 分类模型, 一部分特征向量输入到 CNN 中进行训练, 剩余特征向量用于测试, 实现对轴承故障类型的有效识别。



图 1 轴承故障诊断流程图

4 实验与分析

本文所选择的轴承数据来自美国凯斯西储大学轴承数据中心。采用直径为 0.1778mm 的故障引入至内滚道、滚动体 (球体) 和外滚道, 选择驱动端的振动信

号作为样本数据。选用电机转速为 1750r/min、1772r/min、1797r/min 轴承端正常振动数据及内滚道、滚动体 (球体) 和外滚道轴承故障振动数据。当采样频率 $f_s=12\text{kHz}$ 时, 将每种状态下收集到的振动数据进行划分, 将 1024 个数据点作为一个样本, 划分后四种类别内圈故障, 外圈故障, 滚动体故障, 正常, 各有 300 个样本, 共 1200 个样本, 在不同训练集数量下, 得到各自的准确率。

对信号进行 CEEMDAN 分解得到若干个 IMF 分量, 相关性高的 IMF 分量能够表征振动信号的真实特征信息。因此, 本文通过计算原始信号与各 IMF 分量的相关系数, 剔除低相关性的无关分量, 筛选出具有典型故障特征的高相关 IMF 分量。设有两个长度均为 N 的信号 $s_1(t)$ 和 $s_2(t)$, 那么相关系数 Q_s 计算 [17] 如公式(23) 所示。

$$Q_s = \frac{\sum_{t=1}^N s_1(t)s_2(t)}{\sqrt{\sum_{t=1}^N s_1^2(t)\sum_{t=1}^N s_2^2(t)}} \quad (23)$$

表 1 给出一组数据的 IMF1 到 IMF7 的相关系数, 其中 IMF6 和 IMF7 分量计算的相关系数小于 0.01, 说明该分量与原始信号的相关性较小, 该分量不仅不能有效地描述原始信号的特征信息, 还会对后续的故障识别产生一定干扰。因此, 本文将后续这些虚假分量从分解结果中剔除, 仅保留前 5 个 IMF 分量用于描述故障信号的特征信息, 即设置故障特征向量的维度为 5。

表 1 IMF1-IMF7 的相关系数

IMF 分量信号	相关系数
IMF1	0.9864
IMF2	0.1599
IMF3	0.0736
IMF4	0.0569
IMF5	0.0351
IMF6	0.0079
IMF7	0.0069

图 2 所示为通过卷积神经网络训练后得到的测试集混淆矩阵, 其中数字 1, 2, 3, 4, 代表四种类别: 滚动体故障, 内圈故障, 外圈故障, 正常, 竖轴代表真实样本类别, 横轴代表预测样本类别。图 3 所示为训练集为 20% 的比例下通过卷积神经网络训练得到的测试集准确率。不同训练集比例得到准确率如表 2, 当训练集比例为 20% 时, 故障识别准确率为 99.3%, 当训练集比例高于 30% 时, 故障识别准确率为 100%。本文方法与其他相关方法比较如表 3 所示。可以看出, 本文提出的方法有更好的识别效果。

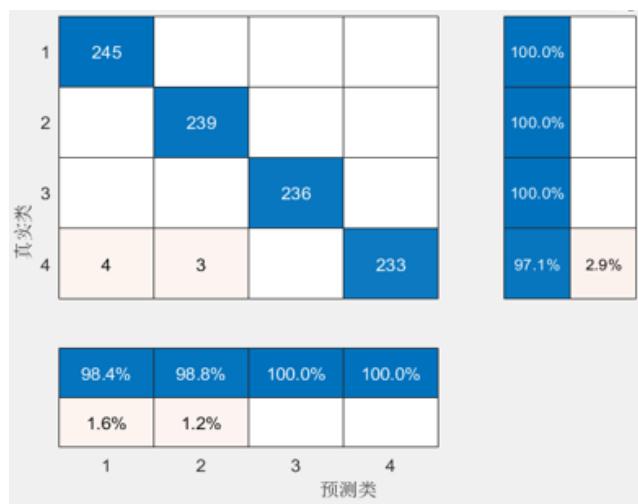


图 2 训练集混淆矩阵

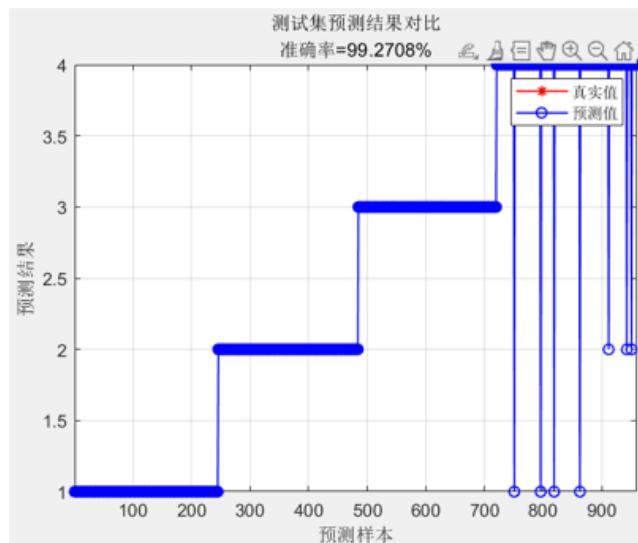


图 3 测试集准确率

表 2 故障识别准确率

训练集比例	准确率
20%	99.3%
25%	99.9%
30%	100%
40%	100%
50%	100%

表 3 不同方法的故障识别准确率

方法	准确率
本文 CEEMDAN-SVD+CNN 方法	99.3%
VMD 方法[2]	96.7%
CEEMD-SVD+ELM 方法[3]	95.0%
EEMD-Renyi 熵+PCA-PNN]方法[11]	91.7%
CNN 方法[13]	99.2%

5 结论

本文提出了一种滚动轴承故障识别方法，首先采用了 CEEMDAN 算法分解电机轴承的振动信号，根据原始信号与 IMF 分量的相关系数筛选出相关系数较高的 IMF 分量，并对其进行奇异值分解获得奇异值，再计算奇异值的 Renyi 熵以组成故障特征向量。最后通过卷积神经网络进行故障类型识别，本文当训练集比例占 20% 时，识别准确率为 99.3%。故障信号检测准确率为 100%，表明本文方法有很好的故障识别效果。

参考文献

- [1] Zhiwei C, Xuejiao L, Guangbin P, et al. Transfer Deep Learning Network for Rolling Bearing Fault Diagnosis of Wind Turbines [J]. Journal of Physics: Conference Series, 2023, 2503(1).
- [2] 许立环, 王春, 徐翔等. 基于自适应变分模态分解的滚动轴承故障诊断研究 [J]. 工业控制计算机, 2021, 34(12): 86-88+91.
- [3] 吴漫, 黄国勇, 周卫兵. 基于 CEEMD-SVD 和 ELM 的滚动轴承故障诊断 [J]. 化工自动化及仪表, 2018, 45(10): 784-788.
- [4] 曾梦洁, 李舜酩, 陆建涛等. 基于深度神经网络的嵌入式轴承故障智能诊断系统 [J]. 工业控制计算机, 2021, 34(10): 41-43+47.
- [5] 李俊卿, 张承志, 胡晓东, 等. 基于 CNN-ViT 的滚动轴承故障类型识别方法 [J]. 电力科学与工程. 2023, (2): 64-71.
- [6] 肖俊青, 金江涛, 李春, 等. 基于 CEEMDAN 模糊熵 CNN 轴承故障诊断研究 [J]. 机械强度. 2023, (1): 26-33.
- [7] 苏文胜, 王奉涛, 张志新, 等. EMD 降噪和谱峭度法在滚动轴承早期故障诊断中的应用 [J]. 振动与冲击. 2010, (3): 18-21.
- [8] 杨杰. 声发射技术在超低速轴承故障诊断中的应用研究 [D]. 兰州理工大学, 2017.
- [9] 李军, 李青. 基于 CEEMDAN-排列熵和泄漏积分 ESN 的中期电力负荷预测研究 [J]. 电机与控制学报. 2015, (8): 70-80.
- [10] Dou S. K., Zhang L. Y., Li C. X.. Improved EMD-PSO-LSSVM train wireless network time-delay prediction [P]. Dalian Jiaotong University (China), 2022.
- [11] 窦东阳, 李丽娟, 赵英凯. 基于 EEMD-Renyi 熵和 PCA-PNN 的滚动轴承故障诊断 [J]. 东南大学学报: 自然科学版. 2011, (S1): 107-111.

- [12] 张丽艳, 温万钦. 一种基于 DWT-HD-SVD 的数字图像水印算法 [J]. 大连交通大学学报, 2022, 43(06): 105-109+115.
- [13] 罗洁思, 张绍辉, 李叶妮. 多分辨奇异值分解在滚动轴承振动信号解调分析中的应用 [J]. 振动工程学报. 2019, (6): 1114-1120.
- [14] Srikrushna S B, Damodar S S, Rameshpant S G. Renyi entropy and deep learning-based approach for accent classification [J]. Multimedia Tools and Applications, 2021, 81(1).
- [15] 刘禛. 基于深度学习的轴承故障诊断研究 [D]. 集美大学, 2022.
- [16] Bengio Y, Glorot X. Understanding the difficulty of training deep feed forward neural networks [C]. proceedings of the thirteenth international conference on artificial intelligence and statistics. 2010: 249-256.
- [17] 宋立业, 孙琳. EEMD-GSSA-SVM 滚动轴承故障诊断方法研究 [J]. 传感器与微系统, 2022, 41(04): 56-59.

作者简介

张丽艳

1974 年生, 副教授, 博士. 研究方向为无线通信、信号与信息处理、嵌入式系统开发.

E-mail: zhangliyan@126.com

王振宇

2000 年生, 硕士生. 研究方向为振动信号处理.

E-mail: m18341802566@163.com

李林

1982 年生, 博士生. 研究方向为振动信号处理.

E-mail: 18842626868@163.com