DOI：10.13890/j.issn.1000-128X.2023.01.006　　文章编号：1000-128X(2023)01-0042-09

基于ICEEMDAN-MPE-RF和SVM的齿轮箱特征提取与故障诊断

丁晓锋，张宇华
（上海电力大学 电气工程学院，上海 200090）

摘　要：针对齿轮箱非平稳振动信号特征提取难、特征向量冗余度高和故障识别率低的问题，提出基于改进的自适应噪声完备集成经验模态分解（Improved complete ensemble empirical mode decomposition with adaptive noise，ICEEMDAN）、多尺度排列熵（Multi-scale permutation entropy，MPE）、随机森林（Random forest，RF）特征重要性排序和支持向量机（Support vector machine，SVM）的齿轮箱特征提取与故障诊断方法。首先，通过ICEEMDAN将各种故障状态的齿轮振动信号分解为一系列不同频率分布的本征模态分量（Intrinsic mode functions，IMF）；然后，计算各阶IMF的MPE值获得非平稳信号时频分布下的非线性动力学特征；最后，通过RF算法评估特征重要性，选择高重要性敏感特征组成最优特征子集输入SVM进行故障模式识别。试验结果表明，该方法特征提取和表征能力强，在不同工况下的平均识别率可达99.79%，在多工况和小样本数据集上比其他方法更具稳健性。

关键词：齿轮箱；改进的自适应噪声完备集成经验模态分解；多尺度排列熵；随机森林；支持向量机；特征提取；故障诊断

中图分类号：TH17；TH132　　**文献标识码：**A

Feature extraction and fault diagnosis of gearbox based on ICEEMDAN, MPE, RF and SVM

DING Xiaofeng, ZHANG Yuhua

(College of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: To solve the challenges related to non-stationary vibration signals in gearboxes, i.e. difficult feature extraction, high redundancy of feature vectors and low fault identification rate, this paper proposed a method of feature extraction and fault diagnosis of gearboxes based on the improved complete ensemble empirical mode decomposition with adaptive noise (ICEEMDAN), multi-scale permutation entropy (MPE), random forest (RF) feature importance ranking and support vector machine (SVM). Firstly, the vibration signals of gears in various fault states were decomposed into a series of intrinsic mode functions (IMF) with different frequency distributions by ICEEMDAN. Then, the MPE values of the IMFs were calculated to obtain the nonlinear dynamic features of non-stationary signals in time-frequency distribution. Finally, the importance of such features was evaluated by the RF algorithm, and the sensitive features with high importance were selected to form the optimal feature subset as the input to SVM for fault pattern recognition. The experimental results show that this method with strong feature extraction and representation ability and as high as 99.79% recognition rate on average under different operating conditions is more robust in multi-operating conditions and small sample data sets, compared with other methods.

Keywords: gearbox; improved complete ensemble empirical mode decomposition with adaptive noise (ICEEMDAN); multi-scale permutation entropy (MPE); random forest (RF); support vector machine (SVM); feature extraction; fault diagnosis

---

基金项目：上海绿色能源并网工程技术研究中心项目(13DZ2251900)；上海市科技创新行动计划项目(19DZ2204700)
通信作者：张宇华（1975—），男，博士，副教授，主要从事电力设备故障诊断和状态监测；E-mail：zhyhdq@126.com
引用格式：丁晓锋, 张宇华. 基于ICEEMDAN-MPE-RF和SVM的齿轮箱特征提取与故障诊断[J]. 机车电传动, 2023(1): 42-50.
Citation: DING Xiaofeng, ZHANG Yuhua. Feature extraction and fault diagnosis of gearbox based on ICEEMDAN, MPE, RF and SVM[J]. Electric Drive for Locomotives, 2023(1): 42-50.

0　引言

齿轮箱作为机车传动系统的关键部件[1]，经常在高速、重载和强冲击环境下运行，极易发生故障。因此，齿轮箱运行状态的监测和早期故障的智能诊断对提高机车运行可靠性具有重要意义。

近年来，随着传感技术和人工智能的发展，基于振动信号的数据驱动方法已成为齿轮箱故障诊断的新方向[2]。基于数据驱动的故障诊断方法通常包括：数据采集、特征提取和模式识别[3]。其中，最关键的是提取能够全面表征故障信息的特征。研究表明，有缺陷的机械通常表现出复杂的动力学行为[4]。熵作为一种测量时间序列不确定性和无序性的统计指标，可通过考虑时间序列的非线性行为量化复杂性并检测动态变化[5]，近年来已被广泛应用于旋转机械的故障诊断。文献[6]提取广义排列熵作为特征值来辨别不同类型和不同严重程度的齿轮故障。文献[7]利用改进多尺度加权排列熵提取行星齿轮箱不同工况下的故障特征来诊断各齿轮故障类型。文献[8]提出了一种多尺度符号多样性熵并对行星齿轮箱7种典型故障的动态复杂性进行了量化。文献[9]使用MPE对旋转机械的振动信号进行了定量分析，证明了其在多个时间尺度上表征故障信息的能力。上述文献使用各种熵来表征齿轮故障信息，取得了不错的效果。然而，受传递效应和多激励耦合的影响，振动信号通常表现为非平稳性[10-11]，故障相关特征极其微弱，直接检测振动信号的动力学突变难以有效挖掘故障信息，影响故障诊断的准确性。

迄今为止，时频分析是处理非平稳信号的主要方法[12]，近年来，一些研究将时频分析和动力学分析相结合进行特征提取。文献[13]使用参数优化的变分模态分解将齿轮箱振动信号进行分解，然后提取各阶分量的时域、频域和时频域信息熵作为特征进行故障分类。文献[14]采用完备集成经验模态分解（Complete ensemble empirical mode decomposition with adaptive noise，CEEMDAN）方法将原始信号分解为6个IMF，用排列熵（Permutation entropy，PE）来反映IMF的时间复杂度，以量化故障特征。文献[15]使用优化的变分模态分解和复合多尺度规范化散布熵进行特征提取构成特征向量进行故障分类。文献[16]采用改进的极点对称模态分解将振动信号进行分解，然后以最大峰度包络谱指数选取敏感分量并计算奇异谱熵、能量熵和排列熵构造特征向量集来识别齿轮箱故障模式。

上述文献将时频分解技术和动力学分析相结合，揭示了非平稳故障信号的时频变化规律和非线性动态变化，取得了显著的效果，但仍存在以下问题：①传统的时频分解方法因存在模态混叠、残差噪声和虚假分量等[17]问题导致时频分辨率低，或因参数的选取无自适应性在工况变化时需重新建模；②通常经时频分解提取特征后构建的原始特征向量集具有高维、冗余等特性，其不仅会增加模型计算成本，而且可能会影响模型的泛化性能。

为了解决以上问题，本文在非线性动力学分析的基础上，引入ICEEMDAN[18]时频分解方法和RF特征优选方法。首先，使用ICEEMDAN将各种故障状态的振动信号根据其内在特性进行自适应分解，以减少模态混叠和模态中的残差噪声，提高时频分辨率，增强故障特征提取能力；然后，计算各阶IMF的MPE值构建特征向量，以量化故障特征；其次，将原始特征向量输入RF进行训练，在其训练中通过衡量特征对分类的贡献量计算重要性分数并自动给出排序结果；最后，根据特征排序结果选择敏感特征输入SVM进行故障分类，以降低信息冗余，加快SVM训练速度。

1　基于ICEEMDAN-MPE-RF和SVM的齿轮箱故障诊断算法原理

1.1　基于ICEEMDAN的齿轮故障信号分解

CEEMDAN是一种具有多分辨率分析能力的自适应信号分解方法，是继集成经验模态分解（Ensemble empirical mode decomposition，EEMD）和互补集成经验模态分解（Complementary empirical mode decomposition，CEEMD）之后对经验模态分解（Empirical mode decomposition，EMD）的又一重大改进，与EEMD和CEEMD相比，CEEMDAN有效改善了EMD的模态混叠问题，模态分量更符合要求、重构误差更小。但在CEEMDAN的计算中，采用与EEMD相同的方法计算第一模态，而在计算其余模态时使用特殊的噪声$E_k\left(w^{(i)}[n]\right)$，这使得其前两个模态产生强烈的重叠，因而在分解早期出现一些伪模态，有效信号出现得较EEMD晚；此外，CEEMDAN的模态仍然包含一些残余噪声。考虑到这些问题，ICEEMDAN在分解的所有阶段都采用$E_k\left(w^{(i)}[n]\right)$噪声，将IMF定义为残差信号与局部均值的差值。ICEEMDAN算法步骤如下:

①向时序信号$x[n]$中依次添加噪声$E_1\left(w^{(i)}[n]\right)$组成含噪混合信号$x^{(i)}[n]$，计算公式如下：

$$x^{(i)}[n]=x[n]+\beta_0 E_1\left(w^{(i)}[n]\right) \tag{1}$$

式中：$w^{(i)}[n]$为第i次添加的高斯白噪声$(0<i\leqslant I)$；$x^{(i)}[n]$为第i次添加噪声后的混合信号；β_0为噪声系数；$E_1\left(w^{(i)}[n]\right)$为信号$w^{(i)}[n]$经EMD分解得到的第1个模态。

②计算混合信号$x^{(i)}[n]$的局部均值，并取I次计算的平均值获得第1个残差，计算公式如下：

$$r_1=\left\langle M\left(x^{(i)}[n]\right)\right\rangle \tag{2}$$

式中：$M(\cdot)$为局部均值运算；$\langle\cdot\rangle$为取平均。

③原始信号$x[n]$与残差r_1之差即为第1个模态分量d_1，计算公式如下：

$$d_1=x[n]-r_1 \tag{3}$$

④向残差r_1依次添加噪声$E_2\left(w^{(i)}[n]\right)$，并求$I$个含噪信号$r_1+\beta_1 E_2\left(w^{(i)}[n]\right)$局部均值的平均值得到第2个残差$r_2$，计算公式如下：

$$r_2=\left\langle M\left(r_1+\beta_1 E_2\left(w^{(i)}[n]\right)\right)\right\rangle \tag{4}$$

⑤残差r_1与r_2的差值即为第2个模态d_2，计算公式如下：

$$d_2=r_1-r_2 \tag{5}$$

⑥对于$k=3,\cdots,K$，计算第k个残差，计算公式如下：

$$r_k=\left\langle M\left(r_{k-1}+\beta_{k-1}E_k\left(w^{(i)}[n]\right)\right)\right\rangle \tag{6}$$

⑦计算第k个模态d_k，计算公式如下：

$$d_k=r_k-r_{k-1} \tag{7}$$

式中：$\beta_k=\varepsilon_k s_{\mathrm{td}}(r_k)$，为第$k$次添加噪声的噪声系数（其中，$\varepsilon_k$为幅值系数；$s_{\mathrm{td}}(r_k)$为残差$r_k$的标准差），用来选择附加噪声与残差之间所期望的信噪比。

1.2 基于MPE的齿轮故障特征提取

1.2.1 PE

PE是一种有效测量混沌时间序列复杂性的指标，特别是存在观测噪声的情况下[19]，与其他复杂度参数相比，PE对噪声扰动更具鲁棒性。PE的计算步骤如下：

①对于给定的时序信号$\boldsymbol{x}=\{x(i),i=1,2,\cdots,N\}$，通过相空间重构映射到$m$维空间：

$$\boldsymbol{H}=\begin{bmatrix}\boldsymbol{H}(1)\\ \cdots\\ \boldsymbol{H}(k)\\ \cdots\\ \boldsymbol{H}(K)\end{bmatrix}=\begin{bmatrix}x(1) & x(1+t) & \cdots & x(1+(m-1)t)\\ \cdots & \cdots & \cdots & \cdots\\ x(k) & x(k+t) & \cdots & x(k+(m-1)t)\\ \cdots & \cdots & \cdots & \cdots\\ x(K) & x(K+t) & \cdots & x(K+(m-1)t)\end{bmatrix} \tag{8}$$

式中：$\boldsymbol{H}$为重构矩阵；m为嵌入维数；t为时延；$K=N-(m-1)t$，为重构向量的个数。

②将分量$\boldsymbol{H}(k)$中的元素按升序排序：

$$x\left(k+(i_1-1)t\right)\leqslant x\left(k+(i_2-1)t\right)\leqslant\cdots\leqslant x\left(k+(i_m-1)t\right) \tag{9}$$

式中：i_1，i_2，…，i_m为分量$\boldsymbol{H}(k)$中元素所在的列索引。

如果$x\left(k+(i_e-1)t\right)=x\left(k+(i_c-1)t\right)$，则按$i_e$和$i_c$的值排序。当$i_e<i_c$时，$x\left(k+(i_e-1)t\right)\leqslant x\left(k+(i_c-1)t\right)$；反之亦然。因此，对于任意分量$\boldsymbol{H}(k)$都存在一组符号序列$(i_1,i_2,\cdots,i_m)$与之对应。假设每个排序出现的概率为$p_j$，则时序信号$\boldsymbol{x}=\{x(i),i=1,2,\cdots,N\}$的PE值为：

$$P_{\mathrm{E}}(\boldsymbol{x},m,t)=-\sum_{j=1}^{q}p_j\ln p_j \tag{10}$$

式中：$\sum_{j=1}^{q}p_j=1$，$q\leqslant m!$。

1.2.2 MPE

MPE是一种改进的PE算法，用于分析不同粒径采样下非线性信号的不规则性和复杂性[20]。主要步骤如下：

①构建粗粒化时间序列。对于给定的时序信号$\boldsymbol{x}=\{x(i),i=1,2,\cdots,N\}$，用一个长度为$s$的窗口在$\boldsymbol{x}$上滑动并计算平均值得到粗粒化时间序列信号$y^{(s)}(j)$：

$$y^{(s)}(j)=\frac{1}{s}\sum_{i=(j-1)s+1}^{js}x(i),j=1,2,\cdots,\left\lfloor\frac{N}{s}\right\rfloor \tag{11}$$

式中：s为尺度因子，决定粗粒化时间序列的长度；$\lfloor\cdot\rfloor$表示向下取整。当s=1时，粗粒度序列为原始序列；当$s>1$时，粗粒度序列长度为$\left\lfloor\frac{N}{s}\right\rfloor$。

②计算每个粗粒度时间序列$y^{(s)}(j)$的PE值，然后表示为尺度因子s的函数：

$$M_{\mathrm{PE}}(\boldsymbol{x},s,m,t)=P_{\mathrm{E}}\left(y^{(s)}(j),m,t\right) \tag{12}$$

1.2.3 MPE参数选取

MPE有3个参数：嵌入维数m、时间尺度s和时延t。BANDT建议嵌入维度取3~7最佳，因为当m太小时，相空间重构过程包含的排列状态太少，无法有效测量混沌系统的动态突变；如果m太大，重构过程的排列状态过多而被均匀化，不仅增加算法计算成本，而且对系统的细微变化不敏感[19]。时间尺度s的选取没有统一的标准，一般选取大于10的某个数[21]。为保持熵与粗粒序列长度$\left\lfloor\frac{N}{s}\right\rfloor$无关，本文选取$s$=16。时延$t$对时间序列计算的影响较小，通常设为1。

为了探究嵌入维数对计算结果的影响，采用高斯白噪声和*1/f*噪声信号对m为3~6下的MPE进行了分析。结果如图1所示。由图1可以看出，当m=3或m=4时，随着尺度因子的增加，噪声的MPE值趋于同质化，无法反映序列的细微变化；当m=5时，随着尺度因子的增加，噪声的MPE变化趋势较为平缓，无法体现多尺度的优势；当m=6时，随着尺度因子的增加，噪声的MPE减小趋势明显且平滑，因此，本文设定m=6。

1.3 基于RF的齿轮故障特征优选

随机森林是决策树和bagging思想的集成算法，通过bootstrap采样选择一个子集训练每棵树，其余样本则作为袋外样本（Out of bag，OOB）用来估计误差，

最终通过投票法获得最优结果。在决策树的生长过程中，每次选择分类效果最佳的特征作为节点进行分裂，通过计算特征在分裂前后的平均基尼指数（Gini index，GI）变化量来评估特征的重要性。

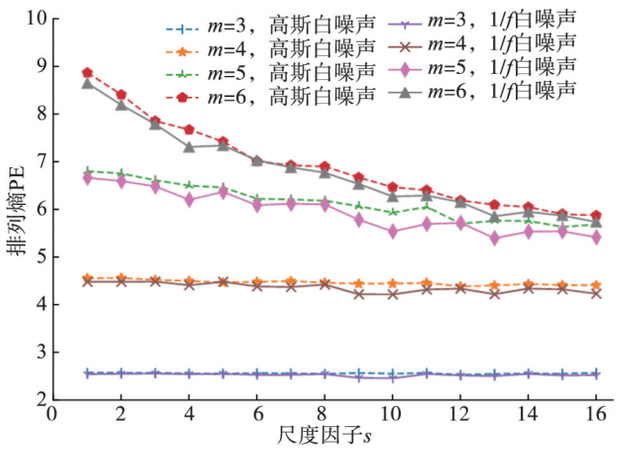


图1　不同嵌入维数下高斯白噪声和1/f噪声的MPE值

Fig. 1　MPE values of Gaussian white noise and 1/f noise under different embedding dimensions

假设某数据集有E个样本、N个特征、Q个类别，特征重要性计算方法如下：

①计算特征F_f（f=1,⋯, N）在节点n（n=1,⋯, N）上GI的变化量，即特征F_f在节点n上的重要性：

$$V_{fn}=G_n-G_u-G_l \tag{13}$$

$$G_n=1-\sum_{q}^{Q}p_{nq}^2 \tag{14}$$

式中：V_{fn}为特征F_f在节点n上的重要性；G_n为节点分裂前的GI；G_u、G_l为分裂后的两个新节点的GI；p_{nq}为节点n样本被分类为q的概率。

②计算特征F_f在第t（t=1,⋯, T）棵决策树上的GI变化量：

$$V_{tf}=\sum_{n=1}^{N}V_{fn} \tag{15}$$

③特征F_f在所有决策树上的总GI变化量为：

$$V_f=\sum_{t=1}^{T}V_{tf} \tag{16}$$

④将其进行归一化处理可得特征F_f在整个数据集上对分类任务的重要性：

$$\overline{V}_f=V_f\left(\sum_{f=1}^{N}V_f\right)^{-1} \tag{17}$$

将归一化后的重要性评分进行排序即可得到特征重要性排序结果。

1.4　基于SVM的齿轮故障模式识别

SVM是一个二分类模型，其主要目的是寻找一个最佳分类决策边界，即超平面。假设给定的数据集$\{x_i,y_i\}$，i=1,2,⋯,N，$x_i\in\mathbb{R}^n$，$y_i\in\{-1,+1\}$是线性划分的，则存在分类超平面$f(\boldsymbol{x})$=0将数据分成两类：

$$f(\boldsymbol{x})=\boldsymbol{\omega}^{\mathrm{T}}\boldsymbol{x}+b=0 \tag{18}$$

式中：$\boldsymbol{\omega}$为超平面的法向量；b为超平面的截距。

符合上述条件的超平面不是唯一的，因此需要找到一个最优分类超平面，使支持向量到超平面的几何距离最大化，表示为以下最优化问题：

$$\min_{\boldsymbol{\omega}}\frac{1}{2}\|\boldsymbol{\omega}\|^2 \tag{19}$$

得到最佳线性分类决策函数：

$$f(\boldsymbol{x})=\mathrm{sgn}\left(\sum_{i,j=1}^{N}a_i^*y_i\left(x_i^{\mathrm{T}}\cdot x_j+b^*\right)\right) \tag{20}$$

式中：a_i^*和b^*是确定最佳线性分类超平面的参数。

实际上数据不可能是完全线性可分的，当存在噪点时，在求解过程中引入松弛变量$\xi_i\geqslant 0$和惩罚因子C，最优化问题变为：

$$\min_{\boldsymbol{\omega}}\frac{1}{2}\|\boldsymbol{\omega}\|^2+C\sum_{i=1}^{N}\xi_i \tag{21}$$

面对非线性问题，引入核函数$K(\boldsymbol{x},\boldsymbol{z})=\varphi(\boldsymbol{x})\varphi(\boldsymbol{z})$，将原始样本空间映射到高维特征空间，得到非线性分割的决策函数：

$$f(\boldsymbol{x})=\mathrm{sgn}\left(\sum_{i,j=1}^{N}a_i^*y_i\left(\varphi(\boldsymbol{x})\cdot\varphi(x_i)+b^*\right)\right) \tag{22}$$

2　基于ICEEMDAN-MPE-RF和SVM的齿轮箱故障诊断流程

基于ICEEMDAN-MPE-RF和SVM的齿轮箱故障诊断流程如图2所示，具体步骤如下：

①信号采集。在一定采样频率下，从齿轮箱故障试验平台分别采集不同故障状态下的振动加速度信号。

②特征提取。首先，通过ICEEMDAN将每种状态的数据样本分解为一系列的IMF；然后，提取IMF的MPE值作为原始特征向量。

③特征选择。通过RF算法评估特征重要性，根据排序结果使用叠加验证法确定最佳特征子集。

④模式识别。将优选后的最佳特征子集随机切分为训练集（占80%）和测试集（占20%），将训练集输入SVM进行训练，使用网格搜索和5折交叉验证法优化参数以保证找到全局最优解，输出SVM在测试集上的诊断结果。

3　试验验证

3.1　试验数据说明

本文使用QPZZ-II机械故障模拟及试验平台(如图3所示)模拟了4种不同转速–载荷电流工况下的6种行星齿轮箱典型故障（如表1所示），行星齿轮箱状态包括：大齿轮断齿故障（简称“断齿”）、大齿轮点蚀故障（简称“点蚀”）、小齿轮磨损故障（简称“磨损”）、大齿轮断齿与小齿轮磨损复合故障（简称“断磨”）、

大齿轮点蚀与小齿轮磨损复合故障（简称“点磨”）以及正常状态，采样频率为5.12 kHz，每种状态共采集到53 248个样本点，试验数据具体信息如表1所示。图4展示了工况1下6种状态部分样本数据（样本长度为2 048）的振动信号原始时域波形图。

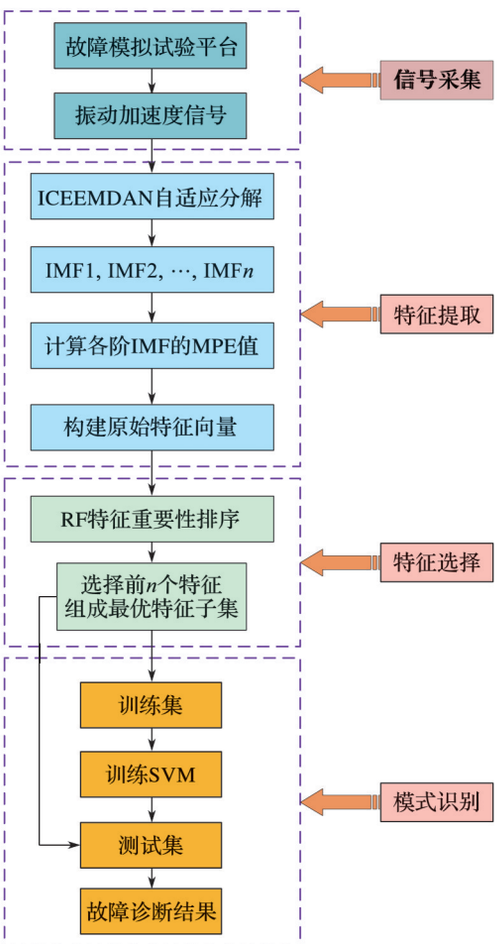


图2 基于ICEEMDAN-MPE-RF与SVM的齿轮箱故障诊断流程图

Fig. 2 Fault diagnosis flow chart of gearbox based on ICEEMDAN-MPE-RF and SVM

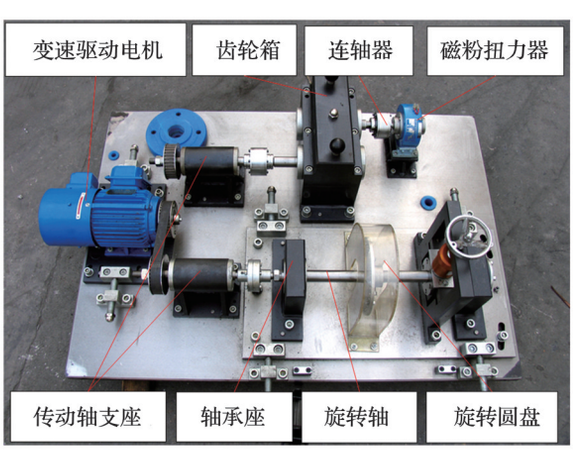


图3 齿轮箱故障模拟试验平台

Fig. 3 Test platform for gearbox fault simulation

由于采集的数据较少，为了扩充数据，采用滑动窗口采样进行数据重采样，采样过程如图5所示。本文中取滑动窗口大小N=2 048，移动步长s=512，因此每种状态获得样本总数为100。

表1 试验数据详细信息

Table 1 Detailed experimental data

工况	转速/(r·min^{-1})	载荷电流I/A	齿轮箱状态
1	880	0.20	正常/断齿/点蚀/磨损/断磨/点磨
2	880	0.10	正常/断齿/点蚀/磨损/断磨/点磨
3	880	0.05	正常/断齿/点蚀/磨损/断磨/点磨
4	1 500	0	正常/断齿/点蚀/磨损/断磨/点磨

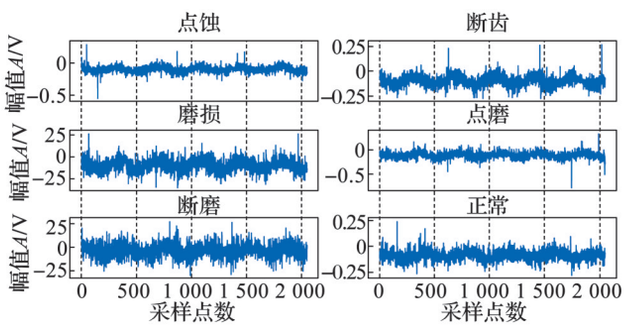


图4 不同状态下的原始振动信号

Fig. 4 Raw vibration signals in different states

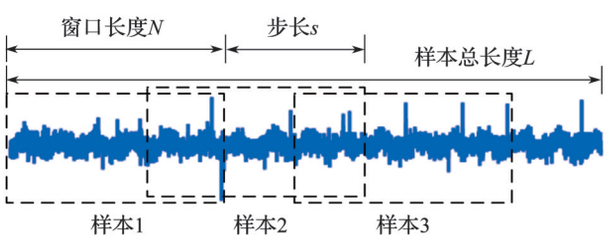


图5 滑动窗口采样原理

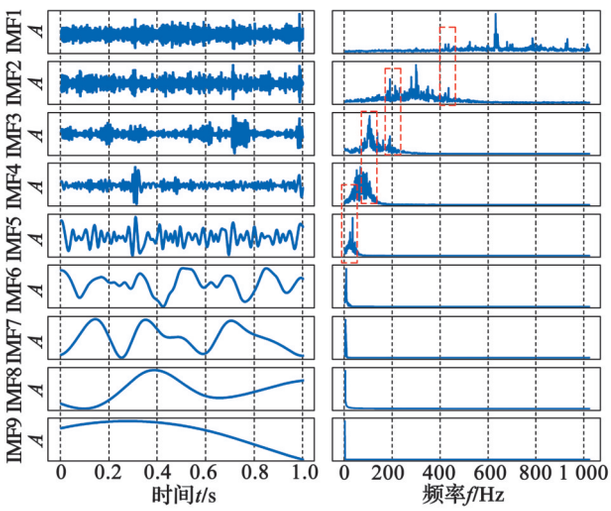
Fig. 5 Sliding window sampling principle

3.2 特征提取

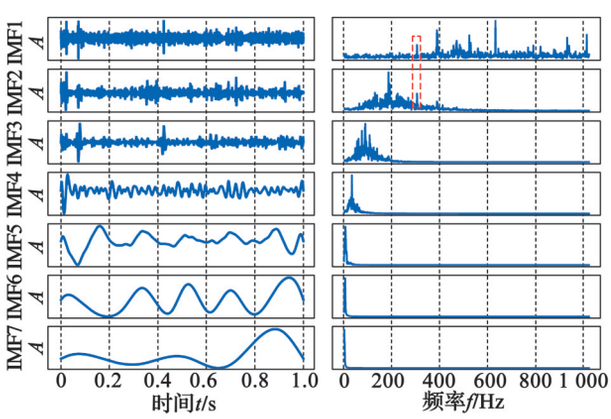
根据故障诊断流程，首先需要对振动信号进行ICEEMDAN分解。为体现ICEEMDAN的分解性能，将其与CEEMDAN分解结果进行对比。限于篇幅，图6仅展示工况1下点蚀故障分解结果。由图6(a)可知，CEEMDAN虽能大致分解出点蚀故障信号中的不同频率分量，但IMF1~IMF5不同分量间均出现了相同的频率成分（如图6中红色虚线框所示），即出现了模态混叠，且分解后期出现了较多的无关分量，分解效率较低。ICEEMDAN能准确地分解出故障信号中的不同频率成分，虽然IMF1和IMF2存在局部轻微频率重叠，但整体各分量频率分离效果较好，且无关分量较少，分解效率高，适合于齿轮箱故障信号的分析。

其次，提取ICEEMDAN分解后的IMF的MPE值作为特征。由于不同样本分解之后的IMF可能数量不一且低频分量所含的故障信息极少，因此本文只对前5个分量进行分析。限于篇幅，图7仅展示了工况1下IMF1和IMF2中的MPE值分布结果。由图7可知，IMF1中尺度1~5以及IMF2中尺度1~5和尺度8~11上6种状态的PE值分布比较分散，对故障状态的区分能力

较好。IMF1中尺度10~16和IMF2中尺度12~16上6种状态的PE值分布区域几乎重合，不利于区分故障状态。



(a) CEEMDAN



(b) ICEEMDAN

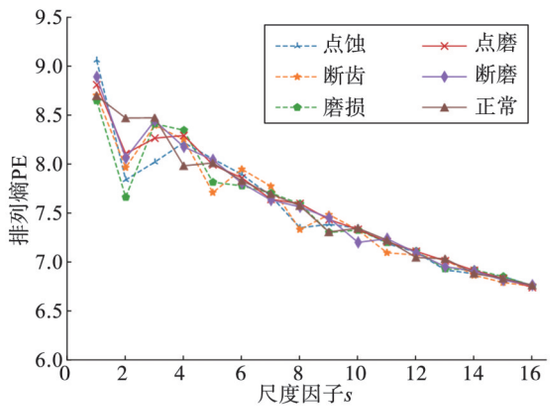
图6　CEEMDAN和ICEEMDAN分解结果

Fig. 6　Decomposition results of CEEMDAN and ICEEMDAN

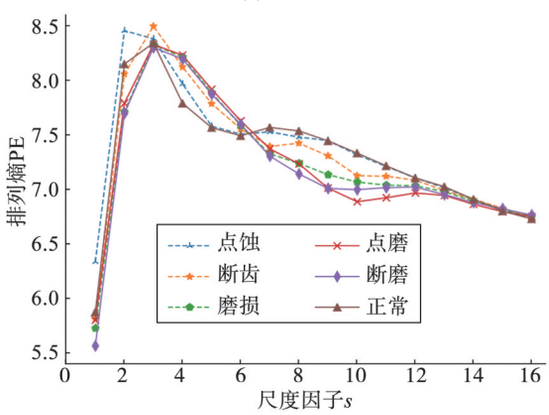
3.3　特征优选

由上述分析可知，不同分量不同时间尺度内的PE值对故障状态的表征能力不同。为了选出具有强表征能力的特征，使用RF计算每个特征对分类的重要性程度，然后对其重要性评分进行排序，图8所示为工况1下排序结果的前20个特征及其重要性评分。由图8可知，IMF1中第2个时间尺度上的PE值重要性分数最高，对故障区分能力最强。其次，IMF1中的前5个尺度以及IMF2中前2个尺度上的PE值重要性分数也相对较高，对故障也有较好的区分能力。此外还可以发现，重要性分数较高的PE特征多集中在IMF1和IMF2内，这是因为齿轮发生故障时会引发高频冲击信号，因此高频分量所含的故障信息较多。

为了确定最佳特征子集，按排序结果将特征依次叠加，通过识别精度的变化来确定最佳特征数，结果如图9所示。由图9可知，工况1和工况3下分别使用



(a) IMF1



(b) IMF2

图7　IMF1和IMF2的MPE平均值

Fig. 7　MPE average value of IMF1 and IMF2

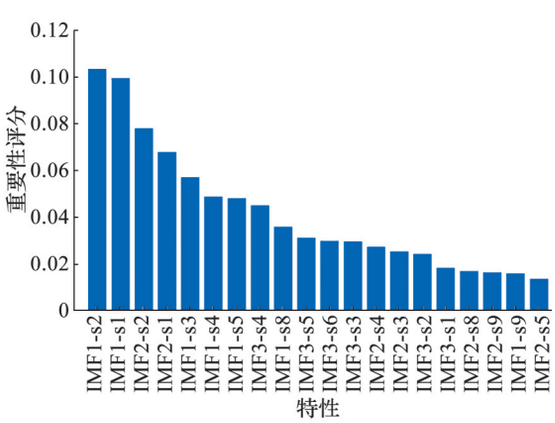


图8　特征重要性排序结果

Fig. 8　Results of importance ranking among feature

前5个和前4个特征时准确率就已达到100%，工况2使用前9个特征时达到100%，工况4使用前11个特征时达到最佳99.17%。同时，随着特征数继续增加，工况2和工况4出现了波动，这可能是不相关或冗余特征误导所致。因此，选取各种工况下排序结果的前11个特征作为最佳特征子集。

3.4　试验结果分析与比较

3.4.1　本文方法结果分析

为了更加直观地体现所提方法在时频分解、特征提取和特征选择方面的优越性，分别设置了以下几组

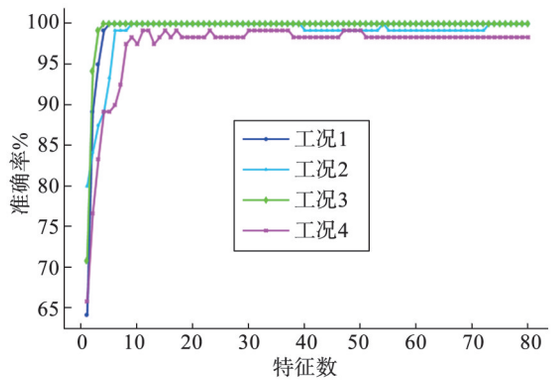


图9　不同工况下特征数与准确率的关系

Fig. 9　Relationship between feature number and accuracy under different working conditions

对比试验，以工况1为例，试验结果如表2所示。由试验2、试验3和试验5可知，通过对振动信号进行时频分解预处理可有效提高分类精度，且本文所用的ICEEMDAN方法优于CEEMDAN，分类精度提高了1百分点。由试验2和试验4对比可知，由于MPE考虑到了振动信号多个尺度内的复杂性和不规则性，因此比单一尺度的PE更能准确地反映复杂时间序列信号的动态变化，分类精度提高了8.33百分点。由试验1、试验2可知，通过RF特征重要性排序进行特征优选后，在不影响识别精度的前提下，运行效率提高了37%以上。由试验1、试验2结合图7可知，通过特征优选后，不仅提高了算法的运行效率，而且由于剔除了大量的不相关或冗余特征，使得模型更具稳定性。

表2　试验结果

Table 2　Experimental result

序号	特征提取方法	识别准确率/%	模型训练时间 t/s
试验1	ICEEMDAN-MPE-RF	100.00	0.053 854
试验2	ICEEMDAN-MPE	100.00	0.085 773
试验3	CEEMDAN-MPE	99.00	0.072 804
试验4	ICEEMDAN-PE	91.67	0.027 916
试验5	MPE	95.00	0.048 869

3.4.2　与其他方法对比分析

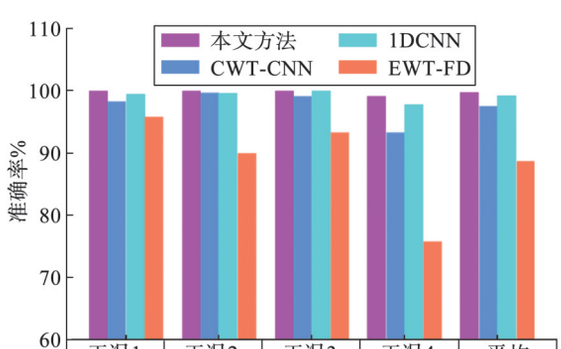
将本文方法与传统主流的时频特征提取方法和目前较为常用的基于深度学习的故障诊断方法进行对比，每种诊断方法的参数设置如下：

①使用经验小波变换（Empirical wavelet transform，EWT）对原始数据进行分解，然后依次提取各个模态分量的petrosian分形维数（Fractal dimension，FD）、katz分形维数和higuchi分形维数，最后使用SVM进行故障模式识别（记为EWT-FD）。

②使用一维卷积神经网络（Convolutional neural network，CNN），以时域信号作为输入（记为1DCNN），输入大小为2 048×1。网络包含3个卷积层、3个最大池化层和2个全连接层。卷积层滤波器数量分别为10、20、40，核大小均为3×1，步长为2；池化层卷积核大小为2×1，步长为2；全连接层神经元数量为120。激活函数为‘relu’，批次大小为32，优化器为‘adam’，初始学习率为0.002，迭代次数为500。

③使用连续小波变换（Continuous wavelet transform，CWT）构造时频图作为CNN的输入（记为CWT-CNN），小波函数选择‘cgau6’。CNN网络采用改进的AlexNet结构：图片输入大小为224×224，第2个全连接层神经元数量改为1 000，在卷积层之后激活层之前加入批量归一化（Batch normalization，BN）层。激活函数为‘relu’，批次大小为64，优化器为‘adam’，初始学习率为0.001，迭代次数为1 000。

不同诊断方法在多工况下的试验结果如图10所示。为保证试验结果的可靠性，以下结果均为5次重复试验的平均值。由图10可知，传统的特征提取方法（EWT-FD）精度较低，特别是在工况4时仅能达到75.83%，在工况变化时精度波动很大。1DCNN和CWT-CNN在工况1、工况2、工况3时性能较好，特别是在工况3下，1DCNN因其出色的非线性拟合能力诊断精度可达100%，但在工况4下，两种诊断方法的精度分别下降6.39%和2.17%，波动较大。本文所提方法在前3种工况下诊断精度均能达到100%，在工况4下精度仅下降0.83%，平均诊断精度可达99.79%，故障诊断结果更稳定。以上试验结果说明，EWT-FD-SVM、1DCNN、CWT-CNN只能应用于特定的工况，而本文方法能够适应多工况的变化。



	工况1	工况2	工况3	工况4	平均
本文方法	100.00	100.00	100.00	99.17	99.79
CWT-CNN	98.33	99.72	99.17	93.33	97.64
1DCNN	99.50	99.67	100.00	97.83	99.25
EWT-FD	95.83	90.00	93.33	75.83	88.75

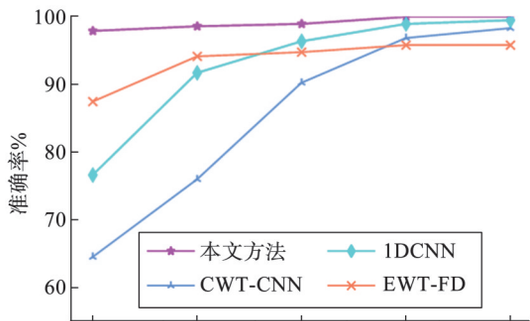
图10　不同工况下与其他方法对比结果

Fig. 10　Comparison results with other methods under different working conditions

3.4.3　样本数量对诊断结果的影响

为了探究样本数量对诊断结果的影响，以工况1为例，图11给出了每类故障样本数据分别为20、40、60、80和100时各模型精度的变化。由图11可知，传统的特征提取方法的诊断精度虽然较低，但受样本数量的影响较小。CWT-CNN虽然具有强大的特征学习能力，但需要大量的样本进行训练，当样本数量较少时，诊断精度急剧下降。本文所提方法在样本数量为20时就

能保持97.92%的准确率，在样本数量为80时准确率即可达到100%，说明本文方法能从齿轮振动信号中准确提取故障特征，特征提取能力和表征能力强。



	20	40	60	80	100
本文方法	97.92	98.61	98.96	100.00	100.00
CWT-CNN	64.58	76.04	90.28	96.88	98.33
1DCNN	76.67	91.74	96.39	98.96	99.50
EWT-FD	87.50	94.17	94.79	95.83	95.83

图 11　不同样本数量下与其他方法对比结果

Fig. 11　Comparison results with other methods under different sample sizes

4　结论

本文提出了一种基于ICEEMDAM、MPE、RF和SVM的齿轮箱特征提取与故障诊断方法，解决了齿轮箱振动信号的非平稳性导致故障特征提取难和故障识别率低的问题，主要结论如下：

①对非平稳振动信号进行时频分解预处理后提取特征能有效提高故障识别精度，且ICEEMDAN比原始的CEEMDAN更有效。

②MPE能够有效表征嵌入到多尺度结构中的齿轮故障信息，比PE更能揭示齿轮非平稳故障信号的动态突变。

③ICEEMDAN和MPE相结合的特征提取方法能够揭示非平稳振动信号在时频分布下的非线性动态变化规律，提高故障诊断精度。

④基于RF的特征优选方法不仅能够降低模型空间复杂度，减少运行成本，而且由于去除了冗余和不相关特征的影响，使得模型诊断结果更稳定。

⑤与EWT-FD-SVM、1DCNN和CWT-CNN相比，本文方法在多工况下具有更高的准确率，在运行工况变化后故障诊断精度波动较小，能够适应多工况的变化。此外，本文方法受样本数量的影响较小，在小样本数据集上依然能保持较高的精度，说明所提方法特征提取和表征能力强，适用于故障样本数据不足的情况。

参考文献：

[1] 李长青, 林建辉, 胡永旭. 优化参数VMD和MED在列车齿轮箱滚动轴承故障诊断中的应用[J]. 机车电传动, 2020(3): 142-147.
LI Changqing, LIN Jianhui, HU Yongxu. Application of optimization parameters VMD and MED in fault diagnosis of train gearbox rolling bearings[J]. Electric Drive for Locomotives, 2020(3): 142-147.

[2] PEI Xinglong, ZHENG Xiaoyang, WU Jinliang. Rotating machinery fault diagnosis through a transformer convolution network subjected to transfer learning[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-11.

[3] WANG Chaoge, LI Hongkun, ZHANG Kongliang, et al. Intelligent fault diagnosis of planetary gearbox based on adaptive normalized CNN under complex variable working conditions and data imbalance[J]. Measurement, 2021, 180: 109565.

[4] 陈鹏, 赵小强, 朱奇先. 基于多尺度排列熵和改进多分类相关向量机的滚动轴承故障诊断方法[J]. 电子测量与仪器学报, 2020, 34(2): 20-28.
CHEN Peng, ZHAO Xiaoqiang, ZHU Qixian. Rolling bearing fault diagnosis method based on multi-scale permutation entropy and improved multi-class relevance vector machine [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(2): 20-28.

[5] LI Yongbo, WANG Xianzhi, LIU Zhenbao, et al. The entropy algorithm and its variants in the fault diagnosis of rotating machinery: a review[J]. IEEE Access, 2018, 6: 66723-66741.

[6] LIN Jinshan, DOU Chunhong, LIU Yingjie. Feature extraction based on generalized permutation entropy for condition monitoring of rotating machinery[J]. Nonlinear Dynamics, 2022, 107(1): 855-870.

[7] 王振亚, 姚立纲, 蔡永武, 等. 基于熵-流特征和樽海鞘群优化支持向量机的故障诊断方法[J]. 振动与冲击, 2021, 40(6): 107-114.
WANG Zhenya, YAO Ligang, CAI Yongwu, et al. Fault diagnosis method based on the entropy-manifold feature and SSO-SVM[J]. Journal of Vibration and Shock, 2021, 40(6): 107-114.

[8] LI Yongbo, WANG Shun, LI Ni, et al. Multiscale symbolic diversity entropy: a novel measurement approach for time-series analysis and its application in fault diagnosis of planetary gearboxes[J]. IEEE Transactions on Industrial Informatics, 2022, 18(2): 1121-1131.

[9] LI Hongmei, HUANG Jinying, YANG Xiwang, et al. Fault diagnosis for rotating machinery using multiscale permutation entropy and convolutional neural networks[J]. Entropy, 2020, 22(8): 851-874.

[10] XU Xiaoli, LIU Xiuli. Fault diagnosis method for wind turbine gearbox based on image characteristics extraction and actual value negative selection algorithm[J]. International Journal of Pattern Recognition and Artificial Intelligence, 2020, 34(14): 2054034.

[11] ZHANG Xun, XU Guanghua, KUANG Jiachen, et al. A three-phase current tacholess envelope order analysis method for feature extraction of planetary gearbox under variable speed conditions[J]. Sensors, 2021, 21(17): 5714-5735.

[12] SHI Haiyang, QIN Yi, WANG Yi, et al. An improved Viterbi algorithm for adaptive instantaneous angular speed estimation and its application into the machine fault diagnosis[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-11.

[13] 党建, 罗燚, 田录林, 等. 基于优化的VMD融合信息熵和FA_PNN的风电机组齿轮箱故障诊断[J]. 太阳能学报, 2021, 42(1): 198-204.
DANG Jian, LUO Yi, TIAN Lulin, et al. Fault diagnosis of wind turbine gearbox based on optimized VMD fusion information entropy and FA_PNN[J]. Acta Energiae Solaris Sinica, 2021, 42(1): 198-204.

[14] KUAI Moshen, CHENG Gang, PANG Yusong, et al. Research of planetary gear fault diagnosis based on permutation entropy of CEEMDAN and ANFIS[J]. Sensors, 2018, 18(3): 782-799.

[15] 王宏伟, 孙文磊, 张小栋, 等. 基于优化VMD复合多尺度散布熵及LSTM的风力发电机齿轮箱故障诊断方法研究[J]. 太阳能学报, 2022, 43(4): 288-295.
WANG Hongwei, SUN Wenlei, ZHANG Xiaodong, et al. Fault diagnosis method of wind turbine's gearbox based on composite multiscale dispersion entropy of optimised VMD and LSTM[J]. Acta Energiae Solaris Sinica, 2022, 43(4): 288-295.

[16] BIE Fengfeng, GU Sheng, GUO Yue, et al. Research on gearbox impact feature extraction method based on improved ESMD[J]. Insight - Non-Destructive Testing and Condition Monitoring, 2022, 64(1): 20-27.

[17] ZHANG Yi, LV Yong, GE Mao. Time-frequency analysis via complementary ensemble adaptive local iterative filtering and enhanced maximum correlation kurtosis deconvolution for wind turbine fault diagnosis[J]. Energy Reports, 2021, 7: 2418-2435.

[18] COLOMINAS M A, SCHLOTTHAUER G, TORRES M E. Improved complete ensemble EMD: a suitable tool for biomedical signal processing[J]. Biomedical Signal Processing and Control, 2014, 14: 19-29.

[19] BANDT C, POMPE B. Permutation entropy: a natural complexity measure for time series[J]. Physical Review Letters, 2002, 88(17): 174102.

[20] AZIZ W, ARIF M. Multiscale permutation entropy of physiological time series[C]//IEEE. 2005 Pakistan Section Multitopic Conference. Karachi, Pakistan: IEEE, 2005: 1-6.

[21] HAN Dongying, GUO Xiaoci, SHI Peiming. An intelligent fault diagnosis method of variable condition gearbox based on improved DBN combined with WPEE and MPE[J]. IEEE Access, 2020, 8: 131299-131309.

收稿日期：2022-07-31
修回日期：2022-11-26