



基于混合熵与组合预测模型的 机车轴承故障诊断

赵庆国¹, 杨江天²

(1. 中国铁路郑州局集团有限公司 洛阳机务段, 河南 洛阳 471002;

2. 北京交通大学 机械与电子控制工程学院, 北京 100044)

摘要: 机车轴承剩余使用寿命 (remaining useful life, RUL) 预测对减少机车的计划外维修、提高机车可靠性和安全性具有重要意义。RUL 预测的准确程度取决于所采用的诊断指标和预测模型。文章提出采用复合多尺度模糊熵和复合多尺度分散熵构造混合熵, 从随机性和模糊性两个不同的角度对信号的不确定性进行统一描述, 其性能优于传统的诊断指标, 并在此基础上, 进一步提出基于小波变换、差分自回归移动平均 (autoregressive integrated moving average, ARIMA) 模型和改进 GM(1, 1) 模型混合预测方法。定期采集轴承振动信号, 计算混合熵值, 构成一个时间序列, 用小波变换将混合熵序列分解为不同的小波系数, 然后分别应用递减序列 GM(1, 1) 模型和 ARIMA 模型预测呈现出递减趋势的小波系数和随机趋势的小波系数。通过小波重构得到总的预测结果。试验结果表明, 文章提出的方法能准确预测机车轴承剩余使用寿命。

关键词: 机车寿命; 剩余使用寿命; 混合熵; 组合预测模型; 递减序列 GM(1, 1) 模型; 故障诊断; 轴承

中图分类号: U260.331⁺.2; TH133.33 **文献标志码:** A **文章编号:** 1000-128X(2025)05-0121-07

0 引言

轴箱轴承是机车走行部最关键的零部件之一, 在运行过程中承载复杂, 工作环境恶劣。因此, 轴承剩余使用寿命预测对减少非计划维修、提高机车安全性与可靠性有重要作用^[1]。

轴承使用寿命预测的难点在于寻找合适的反映轴承工作状况的诊断指标^[2]。几乎所有类型的轴承故障都会引起振动信号幅值的增加, 尤其是特征的变化, 因此可以从振动信号中提取很多特征参数反映轴承的工作^[3]。但是这些参数与轴承型号、转速、信号采样频率等诸多因素有关, 难以做到归一化, 振动信号作为诊断指标使用很不方便^[4]。

熵可从系统的角度描述时间序列的复杂度, 而熵值可用于量化特定过程的动态变化, 并且熵值是无量纲参数, 适合作为诊断指标监测故障随时间的发展趋

势, 用于机器剩余使用寿命预测, 目前已经有很多成功的案例^[5-6]。各种形式的熵函数不断被推出, 从最开始的香农熵和信息熵, 到模糊熵 (fuzzy entropy, FE)、样本熵、能量熵、近似熵、排列熵和散布熵^[7-8]。这些熵函数存在共同的特征, 就是从单一的角度描述信号的复杂性与动态变化, 但是到目前为止, 还没有找到一种特征参数能反映所有类型的故障及其不同发展阶段。因此, 构造混合熵从系统的角度统一描述信号复杂性的变化对轴承剩余使用寿命预测有重要意义。

轴承剩余使用寿命预测的另一个难点是缺乏合适的预测模型。轴承故障受到很多因素的影响, 故障随时间的发展变化复杂, 存在多种趋势, 其中既有确定性的趋势, 又有随机性波动趋势^[9-10]。由于找不到一个诊断指标能完整、充分地描述所有类型的电机故障及其不同发展阶段, 监测轴承运行状况必须使用多个诊断指标, 尤其是进行中长期故障预测时更是如此。常用的多变量预测模型一般只能用于短期预测^[11]。人工

基金项目: 国家自然科学基金项目 (51975040)

通信作者: 赵庆国, 男, 高级工程师, 主要从事机车运用与维护的研究; E-mail: zhaoqingguo0228@163.com

引用格式: 赵庆国, 杨江天. 基于混合熵与组合预测模型的机车轴承故障诊断[J]. 机车电传动, 2025(5): 121-127. DOI: 10.13890/j.issn.1000-128X.2025.05.103.

Citation: ZHAO Qingguo, YANG Jiangtian. Locomotive bearing fault diagnosis using hybrid entropy and combined forecasting model[J]. Electric drive for locomotives, 2025(5): 121-127. DOI: 10.13890/j.issn.1000-128X.2025.05.103.

神经网络可以实现多变量、复杂趋势长期预测,但是需要大量的样本训练^[12],而工业现场的剩余使用寿命预测往往无法获得大量的样本,使用受到限制。

本文提出基于混合熵和组合预测模型的机车轴承故障预测方法;针对缺乏有效诊断指标的难题,本文还提出用复合多尺度模糊熵与复合多尺度散布熵构造混合熵的新诊断指标,从随机性与模糊性两个不同的角度统一描述振动信号的不确定性。

当滚动轴承出现故障时,振动信号表现出明显的周期性特征,振动信号的复杂度将降低,熵值减小。轴承振动信号熵值随时间发展是递减序列。针对常用灰色模型只适合预测增长序列问题,本文提出一种递减序列灰色模型,并在此基础上,构造基于小波变换的组合预测模型,用于机车轴承故障预测,即定期采集机车轴承振动信号,计算混合熵,得到熵值的一个时间序列,对该时间序列做小波分解得到不同的小波系数——对于呈现递减性趋势的小波系数,采用递减序列灰色模型预测;对于波动性的小波系数,建立自回归移动平均 (autoregressive integrated moving average, ARIMA) 模型预测小波系统随时间的变化。最终通过小波重构获取最终的预测结果。通过对HXD3C机车轴箱轴承剩余使用寿命进行分析试验,证实了本文所提方法的有效性。

1 混合熵

作为度量不确定性与不规则性的熵,最早由香农于1948年提出,此后熵算法有了很大发展,多种熵算法被推出。熵是归一化、无量纲参数,受数据长度、采样频率等影响很小。从理论而言,旋转机械振动信号的熵与转速无直接关系,这种优良性质使得熵常被引入用于描述时间序列的复杂性,并作为诊断指标广泛用于故障诊断和故障预测。常用熵函数包括香农熵、功率谱熵、小波熵、能量熵、包络熵、近似熵、模糊熵、样本熵和排列熵等。

以上各种熵都从单一角度描述信号的动态变化,而对于很多系统,随机性与模糊性同时存在。为了统一描述信号的复杂性、检测动态变化,需要构造混合熵^[13],发挥两种以上熵算法各自的优势,使其作为诊断指标,能更准确、更全面地反映轴承工作状态。需要指出的是,在正常状态下,轴承振动信号不确定性较高,熵值较大。当滚动轴承出现故障时,其振动会呈现出周期性的冲击,直观上表现为信号变化更为“规律化”,相应的混合熵值会随之下降。

1.1 复合多尺度模糊熵

模糊熵使用Heaviside函数来识别数据的复杂性,这将减少噪声对计算过程的干扰,提高对动态变化的

敏感性。多尺度能够有效地衡量时间序列在不同尺度下的复杂程度,因而能更好地反映时间序列隐藏在不同尺度的模式信息。然而多尺度熵值的计算对时间序列长度依赖性很大,为了解决此问题,提出了复合多尺度,综合了同一个尺度下多个粗粒化序列的信息,有效地防止时间序列变短而导致熵值突变现象的发生。将复合多尺度和模糊熵结合,提出了复合多尺度模糊熵 (composite multiscale fuzzy entropy, CMFE)^[14],采用相同尺度因子下的不同粗粒化序列的均值作为该尺度因子下的模糊熵值,其计算步骤如下:

①对于时间序列 $\{x(i), i=1, 2, \dots, N\}$, 定义粗粒化序列 $y_k^{(\tau)} = \{y_{k,1}^{(\tau)}, y_{k,2}^{(\tau)}, \dots, y_{k,p}^{(\tau)}\}$, 则

$$y_{k,j}^{(\tau)} = \frac{1}{\tau} \sum_{i=(j-1)\tau}^{j\tau+k-1} x_i \quad \left(1 \leq j \leq \frac{N}{\tau}, 1 \leq k \leq \tau\right) \quad (1)$$

式中: τ 为正整数,称为尺度因子。

②对每个尺度因子 τ , 计算其粗粒序列的模糊熵 $y_k^{(\tau)} (1 \leq k \leq \tau)$, 再对 τ 个熵值求平均, 得到该尺度因子下的CMFE值, 则

$$\eta_{\text{CMFE}}(X, \tau, m, n, r) = \frac{1}{\tau} \sum_{k=1}^{\tau} \text{FuzzyEn}(y_k^{(\tau)}, m, n, r) \quad (2)$$

最终得到的熵值为尺度因子的函数, 通过这样处理, CMFE能够综合所有粗粒化序列的模糊熵信息。

1.2 复合多尺度散布熵

散布熵可以衡量信号的随机特性, 具有很强的抗干扰能力。相比排列熵, 可以更好地反映幅度变化带来的随机特性, 并且计算效率更高。在CMFE定义中, 如果采用散布熵替代模糊熵, 则得到复合多尺度散布熵 (composite multiscale dispersion entropy, CMDE), 计算步骤如下:

①对于初始时间序列 $\{u(i), i=1, 2, \dots, L\}$, 其在尺度因子 τ 下的第 k 个粗粒化序列 $x_k^{\tau} = \{x_{k,1}^{(\tau)}, x_{k,2}^{(\tau)}, \dots\}$ 由下式给出:

$$x_{k,j}^{\tau} = \frac{1}{\tau} \sum_{i=k+\tau(j-1)}^{k+j\tau-1} u_i \quad \left(1 \leq j \leq \frac{L}{\tau}, 1 \leq k \leq \tau\right) \quad (3)$$

②计算 x_k^{τ} 的散布熵, 从而得到各个尺度因子 τ 的CMDE, 其定义为

$$\eta_{\text{CMDE}}(X, m, c, d, \tau) = \frac{1}{\tau} \sum_{k=1}^{\tau} \text{DE}(x_k^{\tau}, m, c, d) \quad (4)$$

CMDE算法在每个尺度上都计算出 τ 个粗粒化序列, 通过对其求平均值, 提高了多尺度分析的稳定性。

1.3 混合熵的构造

复合多尺度模糊熵和复合多尺度散布熵都是以尺度 τ 为自变量的函数, 因此需要从多个尺度中选取最能表征信号状态的尺度来计算熵值, 从而构建混合熵。随机选取采集到的3个振动信号, 从尺度1到尺度20分别计算其CMFE和CMDE, 结果如图1和图2所示。




图1 3个振动信号的复合多尺度模糊熵

Fig. 1 CMFE of three vibration signals




图2 3个振动信号的复合多尺度散布熵

Fig. 2 CMDE of three vibration signals

由图1和图2可知,随着尺度因子增大,3个信号的熵值总体上呈现逐渐下降的趋势。对于多尺度熵而言,若时间序列在尺度因子递增的过程中,其熵值表现为单调递减的状态,那么这反映出该序列的结构相对简单,在小尺度上蕴含了较为丰富的信息。因此,在实际应用中,并不需要选择过大的尺度因子,尺度过大会导致不正确的熵值。此外,当尺度因子设定为1时,复合多尺度模糊熵和复合多尺度散布熵将分别退化为模糊熵和散布熵,此时熵值的结果容易受到噪声的干扰而产生误判。综合各种因素,选择尺度因子2来计算熵值,并将其作为复合多尺度模糊熵和复合多尺度熵的值来构建混合熵。混合熵充分考虑了信号在不同尺度下的模糊性和随机性,其构建如下:

$$\eta_{HE} = \eta_{CMFE}(X, 2, m, n, r) + \eta_{CMDE}(X, m, c, d, 2) \quad (5)$$

在计算中,混合熵的其他参数选择常用值。CMFE中的参数设置为: $m=2$, $n=1$, $r=0.2 \times \text{std}$, 其中 std 为原始时间序列的标准差; CMDE中的参数设置为: $m=3$, $c=6$, $d=1$ 。

2 组合预测模型

2.1 小波变换

小波变换将信号分解成一组占据不同频带的小波

系数,各频带的位置固定且没有重叠。小波变换可以看作是使用低通滤波器和高通滤波器将信号分解成用概貌系数(低频分量)和细节系数(高频分量)表征的量,然后对概貌系数进行再分解,而细节系数保持不变。采用二进小波分解,每次分解得到的概貌系数和细节系数平分原信号所占据的频带,二者等宽。以上性质使得小波变换有很强的数据分解能力,能将复杂序列分解成若干简单的序列之和。当小波变换用于轴承振动信号混合熵值时间序列分析时,低频分量(概貌系数)呈现递减趋势,高频分量(细节系数)呈现随机性趋势。需要指出的是,小波基函数的选择会对分解结果产生影响,本文没有研究讨论最优小波基函数,只选用了常见的sym小波基函数。

2.2 递减GM(1,1)模型

GM(1,1)模型主要通过一阶微分方程的模型来揭示其内部规律,因其具有建模所需数据少、计算简单、适合预测确定性趋势等特点,广泛用于机械故障预测^[15]。需要指出的是,GM(1,1)模型不是直接对输入的序列进行预测,而是对输入的数据进行一次累加生成,对生成序列进行预测,再通过累减运算还原。这种处理方法适用于递增序列,预测递减序列误差较大。为此,本文提出采用线性变换方法,用一个常数对原始序列做减法,得到递增序列,输入GM(1,1)模型预测后,再做逆运算还原。

2.3 ARIMA模型

ARIMA模型是常用的非平稳随机时间序列预测模型,由自回归(autoregressive, AR)模型、移动平均(moving average, MA)模型和差分法组合而成,可用于非平稳随机时间序列的预测。ARIMA建模包括平稳性检验、模型定阶、模型参数估计和模型检验4个步骤。检测通过的模型就可以用于预测,其中模型定阶是最重要、最关键的一步,机械故障预测多通过试算确定。

2.4 组合预测模型

组合预测模型的核心思想是综合利用多种预测方法,以形成更全面、更准确的预测结果。本文提出一种新的组合预测模型,即使用小波变换将时间序列分解,对其中的表现为衰减性的小波系数用递减GM(1,1)模型预测,而对波动性的小波系数用ARIMA模型预测,最后通过小波重构得到最终的预测结果。

组合预测模型的流程如图3所示。首先,从轴承振动信号提取混合熵,对所获得的混合熵时间序列进行4级小波分解。用递减GM(1,1)模型预测小波系数 a_4 ,其余小波系数 $d_4 \sim d_1$ 用ARIMA模型预测,最后通过小波重构获得总的预测。




图3 组合预测模型流程图

Fig. 3 Flowchart of the combined forecasting model

3 工程应用

研究对象为HXD3C型电力机车轴箱轴承, 轴承的检修周期为120万km, 根据洛阳机务段的机车使用情况, 在临近检修期的最后一年, 机车每3次全面整备(大约一周时间)时安排1次试验, 采集轴承的振动信号。图4(a)、图4(b)和图4(c)分别为早期故障、中期故障和晚期故障时的轴承振动信号波形。在轴承早期故障时期, 无法分辨轴承的冲击成分, 波形较为复杂。随着轴承磨损加重, 振动信号的周期性冲击现象愈发明显, 波形变得规律。根据前文的分析, 本文提出的混合熵特征值能与轴承劣化程度建立定量关系。在早期故障时, 轴承振动信号随机性较高, 熵值较大。当滚动轴承出现严重故障时, 轴承振动信号相对简单, 熵值较小。




图4 不同试验时期的轴承振动信号波形

Fig. 4 Bearing vibration signal waveforms during different experimental periods

计算所有振动信号的混合熵值, 得到一组熵值的

时间序列, 总共50个数值, 如图5所示。由图5可知, 随着轴承磨损, 振动信号混合熵的发展趋势变得复杂, 总体表现为递减的趋势, 但也包含随机的波动。这时使用单一模型预测, 难以取得好的效果。




图5 轴箱轴承振动信号的混合熵

Fig. 5 Hybrid entropy of vibration signals from axle box bearing

对时间序列做4级小波分解, 各小波系数如图6所示。需要指出的是, 小波分解结果与分解的级数、选用的小波基函数有关。小波分解的级数越多, 得到的小波系数的平稳性就越好, 但是分解级数增多必然会带来计算量的增加。此外, 分解过程本身存在一定的误差。因此, 分解级数也不宜过多, 一般分解级数采用3~5层。本文选用4级小波分解, 小波基函数选择了常用的sym小波。本例中小波重构误差为 1.1207×10^{-13} , 这表明小波基函数和分解级数的选择是比较合理的。




图6 混合熵时间序列小波分解

Fig. 6 Wavelet decomposition of hybrid entropy time series

由图6可知, 各小波系数占据不同的频带, 小波系数 a_4 的频率最低, 为趋势项, 因而需用递减GM(1,1)模型预测; 从 $d_4 \sim d_1$ 频率依次增加, 都是随机波动趋势, 适用ARIMA模型预测。经小波变换, 原始复杂趋势分解为相对简单的趋势, 可适用单一模型预测。

用序列中前48个数据建模, 最后2个数据用于预

测检验。建立小波系数 a_4 的递减GM(1,1)模型为

$$\hat{x}^{(1)}(k) = 112.1811 - 110.2001e^{0.006343k} \tag{6}$$

对于波动性的小波系数 $d_4 \sim d_1$, 用ARIMA模型进行预测, 通过试算, 确定模型分别为ARIMA(2, 4, 1)、ARIMA(1, 4, 2)、ARIMA(1, 0, 2)、ARIMA(1, 0, 4)。小波系数 a_4 、 $d_4 \sim d_1$ 的模型拟合与预测结果如图7所示(蓝色曲线为实际值, 红色曲线为预测值)。小波重构后得到总的模型拟合与预测结果如图8所示。




图7 各小波系数预测结果

Fig. 7 Forecasts of wavelet coefficients




图8 总体预测结果

Fig. 8 Overall forecasts

引入相对误差 δ 来评价模型拟合与预测结果, 表1列出了小波系数 a_4 、 $d_4 \sim d_1$ 和总的模型拟合误差。

小波系数 a_4 平均拟合误差为0.92%, 用递减GM(1,1)模型预测下降性的趋势能获得较高的精度。小波系数 $d_1 \sim d_4$ 的平均拟合误差为0.87%, 随机波动性的趋势适用ARIMA模型预测。总模型的平均拟合误差为0.95%, 有很高精度。小波变换相当于滤波器组, 各小波系数占据不同的频带且无重叠。与原序列相比, 各小波系数的变化趋势单一且相对简单, 易于选用合适的模型预测, 从而获取高精度。

试验共采集50个混合熵值, 其中最后2个值用于

表1 模型拟合误差

Table 1 Model fitting errors %

小波系数	相对误差最大值	相对误差平均值
a_4	2.18	0.49
d_4	4.12	1.71
d_3	6.63	3.23
d_2	2.51	0.76
d_1	2.37	0.87
总体模型	3.56	1.41

预测精度检验, 结果如表2所示。由表2数据对比可知, 本文提出的组合预测模型的一步预测和二步预测都有很高的精度, 适用于机车轴承使用寿命预测。需要指出的是, 二步预测的误差比一步预测误差大很多。如何进一步改进预测方法, 提高多步精度是今后研究的方向之一。

表2 模型预测误差

Table 2 Model forecasting errors

项点	数据49	数据50
真实值	1.016	0.984
本文模型预测值	1.010	0.996
相对误差/%	0.60	1.20

4 结束语

本文提出用复合尺度模糊熵与复合多尺度散布熵构造混合熵, 从系统角度统一描述振动信号复杂程度, 能准确反映轴承的工作状况, 适合作为剩余使用寿命的诊断指标。混合熵值随轴承的运行存在多种变化趋势, 既有下降趋势又有随机波动趋势。本文提出采用递减灰色模型预测下降趋势, 并在此基础上构建基于小波变换的组合预测模型, 发挥3种预测方法的优势。HXD3C 机车轴箱轴承试验表明本文提出的机车轴承故障预测方法具有较高的拟合精度和预测精度, 有望实现机车轴承故障的中长期预测。

参考文献:

[1] 陈哲, 张森, 王蕾, 等. 电力机车故障预测与健康管理系统总体方案研究[J]. 机车电传动, 2021(3): 125-131.
CHEN Zhe, ZHANG Sen, WANG Lei, et al. Research on the overall scheme of electric locomotive fault prognostics and health management system[J]. Electric drive for locomotives, 2021(3): 125-131.

[2] 宋宏智, 李力, 杨兴宽, 等. 高速机车轴承故障诊断与剩余寿命预测的发展及展望[J]. 轴承, 2020(3): 61-67.
SONG Hongzhi, LI Li, YANG Xingkuan, et al. Development and prospect for fault diagnosis and remain life prediction of high speed locomotive bearings[J]. Bearing, 2020 (3): 61-67.

- [3] 陈仁祥, 吴昊年, 韩彦峰, 等. 融合无量纲指标与信息熵的不同转速下旋转机械故障诊断[J]. 振动与冲击, 2019, 38(11): 219-227.
CHEN Renxiang, WU Haonian, HAN Yanfeng, et al. Rotating machinery fault diagnosis under different rotating speeds based on fusion of non-dimensional index and information entropy [J]. Journal of vibration and shock, 2019, 38(11): 219-227.
- [4] CHEN Z X, YANG Y, HE C B, et al. Feature extraction based on hierarchical improved envelope spectrum entropy for rolling bearing fault diagnosis[J]. IEEE transactions on instrumentation and measurement, 2023, 72: 3518912. DOI: 10.1109/TIM.2023.3277938.
- [5] 冯辅周, 司爱威, 江鹏程. 小波相关排列熵和HMM在故障预测中的应用[J]. 振动工程学报, 2013, 26(2): 269-276.
FENG Fuzhou, SI Aiwei, JIANG Pengcheng. Application of wavelet correlation permutation entropy and hidden Markov model to fault prognostic[J]. Journal of vibration engineering, 2013, 26(2): 269-276.
- [6] 韩昆仑, 宋世勇. 基于Shannon熵的高压直流输电线路单端电气量保护[J]. 科学技术与工程, 2022, 22(15): 6149-6155.
HAN Kunlun, SONG Shiyong. Single ended electrical quantity protection of high voltage direct current transmission line based on Shannon entropy[J]. Science technology and engineering, 2022, 22(15): 6149-6155.
- [7] LI Y B, WANG X Z, LIU Z B, et al. The entropy algorithm and its variants in the fault diagnosis of rotating machinery: a review[J]. IEEE Access, 2018, 6: 66723-66741. DOI: 10.1109/ACCESS.2018.2873782.
- [8] ZHANG H Z, HE S S. Analysis and comparison of permutation entropy, approximate entropy and sample entropy[C]// 2018 International Symposium on Computer, Consumer and Control (IS3C). Taichung: IEEE, 2018: 209-212. DOI: 10.1109/IS3C.2018.00060.
- [9] 王奉涛, 苏文胜. 滚动轴承故障诊断与寿命预测[M]. 北京: 科学出版社, 2018: 59-65.
WANG Fengtao, SU Wensheng. Fault diagnosis and life prediction of rolling bearings[M]. Beijing: Science Press, 2018: 59-65.
- [10] 于德介, 程军圣, 杨宇. 基于EMD和AR模型的滚动轴承故障诊断方法[J]. 振动工程学报, 2004, 17(3): 332-335.
YU Dejie, CHENG Junsheng, YANG Yu. A fault diagnosis approach for roller bearings based on EMD method and AR model[J]. Journal of vibration engineering, 2004, 17(3): 332-335.
- [11] 李权福, 贾晨, 宋冬利, 等. 基于优化Bray-Curtis相异度和PSO算法的轴承剩余寿命预测方法研究[J]. 机车电传动, 2023(3): 90-96.
LI Quanfu, JIA Chen, SONG Dongli, et al. A study on method for bearing residual life prediction based on optimized Bray-Curtis dissimilarity and PSO algorithms[J]. Electric drive for locomotives, 2023(3): 90-96.
- [12] 庞学苗, 裴春兴, 燕春光, 等. 动车组牵引电机接地故障预测[J]. 机车电传动, 2021(4): 126-130.
PANG Xuemiao, PEI Chunxing, YAN Chunguang, et al. Electrical grounding fault prediction of EMU traction motor [J]. Electric drive for locomotives, 2021(4): 126-130.
- [13] 宋颖烁. 基于混合熵和组合模型的机车轴承故障预测[D]. 北京: 北京交通大学, 2024.
SONG Yingshuo. Locomotive bearing fault prediction based on hybrid entropy and combined model[D]. Beijing: Beijing Jiaotong University, 2024.
- [14] 郑近德, 潘海洋, 程军圣, 等. 基于复合多尺度模糊熵的滚动轴承故障诊断方法[J]. 振动与冲击, 2016, 35(8): 116-123.
ZHENG Jinde, PAN Haiyang, CHEN Junsheng, et al. Composite multi-scale fuzzy entropy based rolling bearing fault diagnosis method[J]. Journal of vibration and shock, 2016, 35(8): 116-123.
- [15] 刘思峰, 曾波, 刘解放, 等. GM(1,1)模型的几种基本形式及其适用范围研究[J]. 系统工程与电子技术, 2014, 36(3): 501-508.
LIU Sifeng, ZENG Bo, LIU Jiefang, et al. Several basic models of GM(1,1) and their applicable bound[J]. Systems engineering and electronics, 2014, 36(3): 501-508.

Locomotive bearing fault diagnosis using hybrid entropy and combined forecasting model

ZHAO Qingguo¹, YANG Jiangtian²

(1. Luoyang Locomotive Depot, China Railway Zhengzhou Group Co., Ltd., Luoyang, Henan 471002, China;
2. School of Mechanical, Electronic and Control Engineering, Beijing Jiaotong University, Beijing 100044, China)

Abstract: Remaining useful life (RUL) estimation for bearings plays a key role in reducing unplanned maintenance and improving locomotive reliability and safety. The accuracy of RUL estimation depends on the chosen diagnostic index and forecasting model. This paper proposes the adoption of a novel hybrid entropy that combines the composite multiscale fuzzy entropy (CMFE) and composite multiscale dispersal entropy (CMDE), to uniformly characterize signal uncertainty in terms of randomness and fuzziness. This index outperforms conventional diagnostic indices. On this foundation, a hybrid forecasting approach is employed, which combines wavelet transform (WT), an autoregressive integrated moving average (ARIMA) model and an improved GM(1,1) model. From bearing vibration signals collected on a regular basis, hybrid entropy values were computed to form a time series. The time series of entropy values was decomposed by WT into different wavelet coefficients, and the decrease trend and stochastic trend of these coefficients were captured by the decreasing sequence GM(1,1) model and ARIMA model respectively. Final forecasts were generated by wavelet reconstruction. Experimental results demonstrate the effectiveness of the proposed approach for locomotive bearing RUL prediction.

Keywords: locomotive life; remaining useful life; hybrid entropy; combined forecasting model; decreasing sequence GM(1,1) model; fault diagnosis; bearing