

变速器齿轮故障特征模糊熵提取方法研究*

丁伟^① 张志刚^② 黄捷^③ 陈卫东^①

(^①重庆电子工程职业学院智能制造与汽车学院,重庆 401331; ^②重庆理工大学汽车零部件先进制造技术教育部重点实验室,重庆 400054; ^③重庆青山工业有限责任公司技术中心,重庆 402761)

摘要: 针对样本熵相似性度量函数的突变问题,提出了一种变速器齿轮故障特征模糊熵提取方法。模糊熵通过引入模糊隶属度函数代替样本熵中的硬阈值判据,可以减小模糊熵对参数的敏感度和依赖性。利用模糊熵作为变速器齿轮故障的特征值进行提取包括变速器齿轮正常、齿面轻度磨损、齿面中度磨损和断齿等 4 种工况的振动信号,依据不同的故障对应不同的模糊熵分布,对各种故障状态进行分类。变速器齿轮故障识别的实例验证了模糊熵较样本熵具有较好的故障分类能力。

关键词: 变速器; 齿轮; 故障; 模糊熵; 特征; 提取

中图分类号: TN911 **文献标识码:** A

DOI: 10.19287/j.cnki.1005-2402.2020.02.026

Transmission gear fault feature extraction by using fuzzy entropy

DING Wei^①, ZHANG Zhigang^②, HUANG Jie^③, CHEN Weidong^①

(^①School of Intelligent Manufacturing and Automotive, Chongqing College of Electronic Engineering, Chongqing 401331, CHN; ^②Key Laboratory of Advanced Manufacturing Technology for Automobile Parts, Ministry of Education, Chongqing University of Technology, Chongqing 400054, CHN; ^③Technology Center, Chongqing Tsingshan Industrial Co., Ltd., Chongqing 402761, CHN)

Abstract: Aiming at the abrupt problem of sample entropy similarity measure function, a gear in transmission fault feature extraction method based on fuzzy entropy was proposed. Fuzzy entropy replaced the hard threshold criterion in sample entropy by introducing fuzzy membership function, thus reducing the sensitivity and dependence of fuzzy entropy on parameters. Fuzzy entropy was extracted as the characteristic value of transmission gear failure, the tested signal types were normal, slight-worn, medium-worn and broken-teeth. Due to the different fault type correspondence with different fuzzy entropy, it was used as fault feature to evaluate the different fault condition. Practical results proved that fuzzy entropy had better classification ability than sample entropy.

Keywords: transmission; gear; fault; fuzzy entropy; feature; extraction

变速器作为车辆传动系统关键总成,其工作过程中齿轮失效是变速器典型故障之一。齿轮故障通常引起变速器异常振动和噪声,甚至导致变速器完全破坏。因此,研究变速器齿轮故障的特征提取方法对于变速器台架试验条件下提前预测变速器故障具有重要工程应用价值。研究表明,变速器齿轮发生故障后所表现出的振动信号特征具有典型非平稳性和非线性。因此,研究变速器齿轮故障信号的特征有效提取方法尤为关键^[1-3]。样本熵作为信息熵的一种,是研究非线性时间序列复杂度时常用方法,其与李雅普诺夫指数、K 熵及关联维数等其他常用的非线性动力学方法相比,具有较大优势。例如在计算样本熵过程中所需时

间序列的样本数据量小,具有很好的抗噪声和抗干扰能力,样本熵计算所需的参数在一定变化范围内不会影响样本熵的结果趋势等^[4]。但是,样本熵的计算相似性度量函数通常采用阶跃函数,突变性较大,熵值缺乏连续性,对阈值选取非常敏感。而模糊熵作为一种新型非线性方法,用来对采样序列维数发生变化时衡量其产生新模式概率大小的方法,其物理意义与样本熵相似。并且由于模糊熵采用指数函数代替阶跃函数,指数函数所具有的连续性让采样序列计算得到的模糊熵值呈现跟随参数变化能连续平滑变化的趋势^[5-6]。因此,在研究模糊熵的基础上,提出将模糊熵运用于变速器齿轮故障特征提取,计算不同工况下变

* 重庆市教委科学技术研究项目(KJ1602902)

变速器齿轮的振动信号的模糊熵。同时,为了便于对比,对原始信号的样本熵进行了计算,对比结果表明,模糊熵比样本熵具有更好的故障分类能力。

1 样本熵

假设台架采样得到的原始样本时间序列为: $[x(n)] = x(1), x(2), \dots, x(N)$, 总共得到 N 个采样数据样本点, 则采样序列样本熵值的计算步骤包括^[7-9]:

(1) 将采样时间序列按照采样序号组成一组 m 维的向量, $X_m(1), \dots, X_m(N-m+1)$, 其中,

$$X_m(i) = [x(i), x(i+1), \dots, x(i+m-1)] \quad (i=1, 2, \dots, N-m+1) \quad (1)$$

得到的向量代表采样序列以第 i 点为起始点的 m 个连续的 x 的值。

(2) 定义不同的向量 $X_m(i)$ 与 $X_m(j)$ 之间的距离 $d[X_m(i), X_m(j)] (i \neq j)$ 为两个向量对应元素中计算所得差值中最大的一个, 即:

$$d[X_m(i), X_m(j)] = \max_{k=0, \dots, m-1} |x(i+k) - x(j+k)| \quad (2)$$

(3) 设定一个阈值 $r (r > 0)$, 对每一个采样序列中用于计算的 i 值, 统计得到 $d[X_m(i), X_m(j)] < r$ 的数目 (这里称其为模板匹配数) 及得到的此数目与总参与计算的向量个数 $N-m$ 的比值, 此处记为 $B_i^m(r)$, 即:

$$B_i^m(r) = \frac{\text{num}\{d[X_m(i), X_m(j)] < r\}}{N-m} \quad (3)$$

(4) 定义用于计算的所有得平均值 $B_m(r)$ 为

$$B_m(r) = \frac{\sum_{i=1}^{N-m+1} B_i^m(r)}{N-m+1} \quad (4)$$

(5) 将维数增加到 $m+1$, 重复 (1) ~ (4) 步, 得到 $B_{m+1}(r)$; 这样, $B_m(r)$ 为两个参与计算的采样序列在给定的模板匹配数 r 下匹配 m 个点所得到的概率, 而 $B_{m+1}(r)$ 为两个参与计算的时间序列匹配 $m+1$ 个点所得到的概率。

(6) 在理论上, 此采样序列的样本熵的计算式可定义为

$$\text{SampEn}(m, r) = \lim_{N \rightarrow \infty} \left[-\ln \frac{B^{m+1}(r)}{B^m(r)} \right] \quad (5)$$

当采样时间序列的 N 为有限值时, 此采样序列的样本熵的估计值为

$$\text{SampEn}(m, r) = -\ln \frac{B^{m+1}(r)}{B^m(r)} \quad (6)$$

2 模糊熵

假设采样得到的原始时间序列为: $[x(n)] = x(1), x(2), \dots, x(N)$, 总共得到 N 个采样数据样本点,

计算该采样序列的模糊熵^[10]的步骤为:

(1) 将采样时间序列按照采样序号组成一组 m 维的向量, $X_m(1), \dots, X_m(N-m+1)$, 其中,

$$X_m(i) = [x(i), x(i+1), \dots, x(i+m-1)] - u(i) \quad (i=1, 2, \dots, N-m+1) \quad (7)$$

这些向量表示从第 i 点开始的 m 个连续的 x 的值去掉均值 $u(i)$, 其中,

$$u(i) = \frac{1}{m} \sum_{j=0}^{m-1} x(i+j) \quad (8)$$

(2) 定义不同的向量 $X_m(i)$ 与 $X_m(j)$ 之间的距离 $d[X_m(i), X_m(j)] (i \neq j)$ 为两个向量对应元素中计算所得差值最大的一个, 即

$$d_{ij}^m = d[X_m(i), X_m(j)] = \max_{k=0, \dots, m-1} |(x(i+k) - u(i)) - (x(j+k) - u(j))| \quad (9)$$

式中: $i, j = 1, 2, \dots, N-m+1$; 且 $i \neq j$ 。

(3) 通过模糊函数 $\mu(d_{ij}^m, r)$ 来定义向量 $X_m(i)$ 与 $X_m(j)$ 的相似度 D_{ij}^m , 即

$$D_{ij}^m = \mu(d_{ij}^m, r) = e^{-(d_{ij}^m/r)^2} \quad (10)$$

(4) 定义函数

$$\phi^m(r) = \frac{1}{N-m} \sum_{i=1}^{N-m} \left(\frac{1}{N-m-1} \sum_{j=1, j \neq i}^{N-m} D_{ij}^m \right) \quad (11)$$

(5) 类似地, 将维数增加到 $m+1$, 重复 (1) ~ (4) 步骤, 得

$$\phi^{m+1}(r) = \frac{1}{N-m} \sum_{i=1}^{N-m} \left(\frac{1}{N-m-1} \sum_{j=1, j \neq i}^{N-m} D_{ij}^{m+1} \right) \quad (12)$$

(6) 时间序列的模糊熵定义为

$$\text{FuzzyEn}(m, r) = \lim_{N \rightarrow \infty} [\ln \phi^m(r) - \ln \phi^{m+1}(r)] \quad (13)$$

当 N 为有限数时, 上式表示为

$$\text{FuzzyEn}(m, r, N) = \ln \phi^m(r) - \ln \phi^{m+1}(r) \quad (14)$$

式中: m 为模式维数; r 为相似容限; N 为数据长度。

由样本熵和模糊熵定义可知, 两者都是衡量时间序列复杂度的方法, 所衡量时间序列的复杂度越大, 则熵值越大。但从两者选取的向量相似性度量公式来看, 样本熵采用单位阶跃函数, 而模糊熵则采用模糊函数, 并将模糊隶属度函数引入模糊函数, 以取代样本熵的硬阈值判据, 有效降低了模糊熵对参数选择的依赖性和敏感度, 进而在模糊熵计算过程中通过对时间序列进行均值运算, 有效克服了基线漂移影响。

3 模糊熵和样本熵在实测变速器齿轮故障信号特征提取对比分析

为了验证模糊熵在变速器齿轮故障特征提取中有有效性, 基于实验室的齿轮故障台架, 分别提取变速器正常齿轮、齿面轻度磨损、齿面中度磨损以及齿轮断齿等典型工况的特征信号, 计算得到不同工况实验数据的

模糊熵。图1给出了不同工况采样得到的齿轮振动信号时域波形。从时域波形可以看出,除了断齿故障表现出明显冲击特征外,其他3种工况的时域波形很难得到有效反映变速器齿轮工况信息的特征。

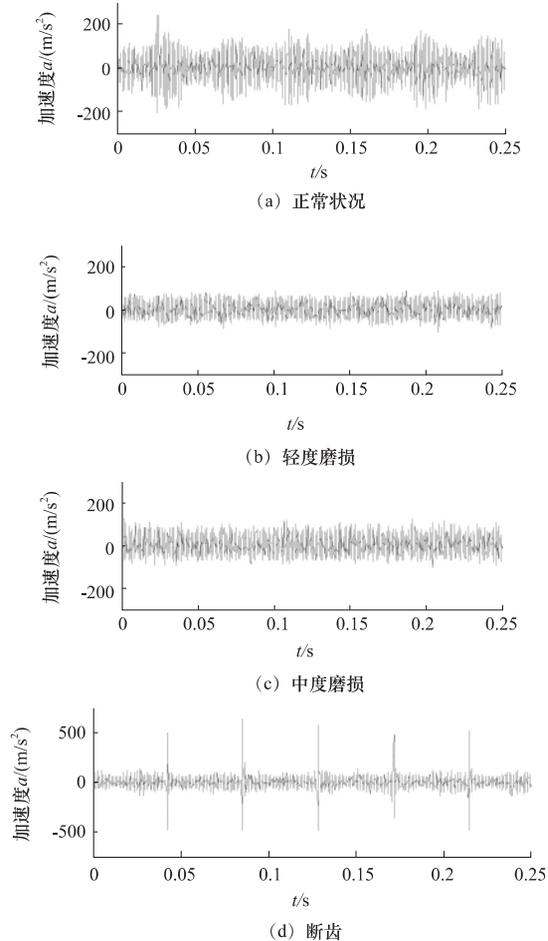


图1 变速器齿轮四种工况数据的时域波形

因此,采用模糊熵作为特征参数,提取变速器齿轮4种不同工况的运行状态特征。在文中研究中, $m=2$, $r=0.2$ Std。限于篇幅,图2给出了每种工况10组采样数据的模糊熵。图中,“·”表示正常齿轮信号的模糊熵,“O”表示齿面轻度磨损故障信号的模糊熵,“+”表示齿面中度磨损故障信号的模糊熵,“×”表示齿面断齿故障信号的模糊熵(以下皆同)。

从图2中可以明显看出,变速器齿轮不同故障信号的模糊熵明显不同,并且各类故障信号的模糊熵一致性较好,能够较好反映出齿轮不同故障的分类特征。从图中还可以看出,由于断齿故障特征最明显,因此其振动信号的复杂度最小,采样数据求得的模糊熵值最小。而齿面轻度磨损在振动信号监测中最不易观察到,因此其所表现出的故障特征最不明显,其振动信号的复杂度高,因此其求得的模糊熵值最大。基于以上良好的分类能力,模糊熵可以用来对变速器齿轮故障

特征提取并进行故障分类。

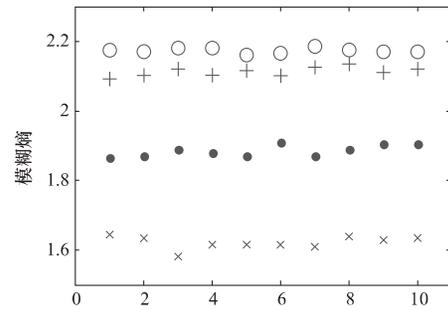


图2 变速器齿轮4种工况数据的模糊熵数据样本

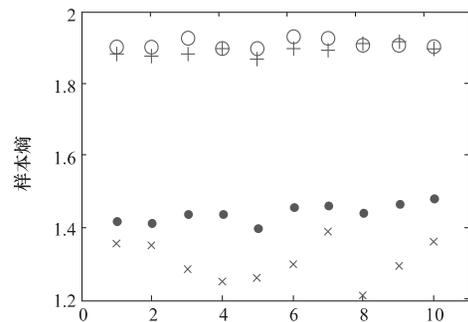


图3 变速器齿轮4种工况数据的样本熵数据样本

以便于比较,图3给出了上述采样数据的样本熵。对比图2、3可知,变速器齿轮轻度磨损和轻度磨损计算得到的样本熵值存在交叉,变速器齿轮断齿计算的样本熵值波动范围较大,与模糊熵相比不能有效用于变速器齿轮不同故障的分类。

4 结语

将模糊熵应用到变速器齿轮故障诊断中,提取了变速器齿轮四种实测工况振动信号的模糊熵,并计算了样本熵进行对比分析。结果表明,模糊熵由于引入了模糊函数,相对样本熵具有更好的分类性。在齿轮故障试验台上实际测得变速器齿轮的不同故障信号,并分别计算得到相应故障信号的模糊熵以及故障分类,为齿轮故障特征提取提供了一条新思路。

参考文献

- [1] 杨晋涛,崔超,冯辅周,等. 基于小波相关—包络排列熵的齿轮故障特征提取[J]. 机械设计与制造, 2015(11): 268-272.
- [2] 彭富强,于德介,武春燕. 基于多尺度线调频基稀疏信号分解中的包络解调方法及其在齿轮故障诊断中的应用[J]. 机械工程学, 2010,46(12): 1-7.
- [3] 李兵,张培林,任国全,等. 运用 EMD 和 GA-SVM 的齿轮故障特征提取与选择[J]. 振动、测试与诊断,2009,29(4): 445-448.
- [4] 来凌红,吴虎胜,吕建新,等. 基于 EMD 和样本熵的滚动轴承故障 SVM 识别[J]. 煤矿机械,2011,32(1): 249-252.
- [5] 郑近德,潘海洋,戚晓利,等. 复合层次模糊熵及其在滚动轴承故障诊断中的应用[J]. 中国机械工程,2016,27(15): 2048-2055.



基于加权排列熵和 DE-ELM 的滚动轴承故障诊断*

吴新忠 张旭 李博华 夏令祥

(中国矿业大学信息与控制工程学院, 江苏 徐州 221116)

摘要: 针对滚动轴承振动信号非平稳非线性的特征, 提出一种基于加权排列熵和差分进化算法优化极限学习机(DE-ELM) 的滚动轴承故障诊断方法。首先利用自适应噪声的完全集合经验模态分解处理轴承振动信号得到固有模态函数(IMF), 然后计算主要 IMF 分量的加权排列熵组成故障特征向量, 最后利用差分进化算法(DE) 优化极限学习机隐含层输入权值和偏置, 并将故障特征向量作为 DE-ELM 的输入。实验证明, 加权排列熵能够精确提取故障特征, DE-ELM 算法能有效提高故障分类精度。与多种方法相比, 该方法更加准确可靠。

关键词: CEEMDAN; 加权排列熵; 差分进化; 极限学习机; 故障诊断

中图分类号: TH133.3 **文献标识码:** A

DOI: 10.19287/j.cnki.1005-2402.2020.02.027

Bearing fault diagnosis of rolling bearing based on weighted-permutation entropy and DE-ELM

WU Xinzhong, ZHANG Xu, LI Bohua, XIA Lingxiang

(School of Information and Control Engineering, China University of Mining and Technology, Xuzhou 221116, CHN)

Abstract: Aiming at the feature that vibration signal of rolling bearing is non-stationary and non-linear, a bearing fault diagnosis method of rolling bearing based on weighted-permutation entropy and differential evolution algorithm(DE) optimized extreme learning machine(DE-ELM) is proposed. Firstly, complete ensemble empirical mode decomposition with adaptive noise was done for vibration signal of rolling bearing to obtain several intrinsic mode functions (IMFs). Then, weighted-permutation entropy of main IMFs was calculated as feature vector of fault signal. Finally, differential evolution algorithm (DE) was used to optimize input weights and hidden layer bias of extreme learning machine, and feature vector of fault signal was taken as input of DE-ELM. The experiment results show that weighted-permutation entropy can accurately extract fault features, and DE-ELM algorithm can effectively improve the accuracy of fault diagnosis. This method is more accurate and reliable compared with several methods.

Keywords: CEEMDAN; weighted-permutation entropy; differential evolution algorithm; extreme learning machine; fault diagnosis

滚动轴承发生故障时, 损伤点重复碰撞与其接触的其他元件从而产生冲击性振动, 致使振动信号多为

非平稳、非线性及多频率信号。如何精确有效地提取故障特征信息并准确分类, 成为旋转机械设备运行状

- [6] 郑近德, 陈敏均, 程军圣, 等. 多尺度模糊熵及其在滚动轴承故障诊断中的应用[J]. 振动工程学报, 2014, 27(1): 145-151.
- [7] Alcaraz R, Rieta J J. A review on sample entropy applications for the non-invasive analysis of atrial fibrillation electrocardiograms [J]. Bio-medical Signal Processing and Control, 2010, 5(1): 1-14.
- [8] Richman J S, Moorman R J. Physiological time-series analysis using approximate entropy and sample entropy [J]. J Physiol Heart Circ Physiol, 2000, 278(6): 2039-2049.
- [9] 赵志宏, 杨绍普. 一种基于样本熵的轴承故障诊断方法[J]. 振动与

冲击, 2012, 31(6): 136-140.

- [10] 杨望灿, 张培林, 王怀光, 等. 基于 EEMD 的多尺度模糊熵的齿轮故障诊断[J]. 振动与冲击, 2015, 34(14): 163-167, 187.

第一作者: 丁伟, 男, 1980 年生, 硕士, 副教授。主要研究方向为汽车故障诊断技术。

(编辑 李静)

(收稿日期: 2019-07-12)

文章编号: 20200229

如果您想发表对本文的看法, 请将文章编号填入读者意见调查表中的相应位置。

* 国家重点研发计划项目(2018YFC0808102); 江苏省重点研发计划项目(BE2016046)