

基于多尺度样本熵改进极限学习机的 列车转向架轴承故障诊断

靳震震¹, 贺德强¹, 苗 剑¹, 徐伟倡²

(1. 广西大学 机械工程学院, 广西 南宁 530004;

2. 南宁中车轨道交通装备有限公司, 广西 南宁 530000)

摘 要: 列车转向架轴承受到轨道激励、运行速度不确定、轨道接缝的冲击振动和其他部件振动因素的影响, 轴承振动信号呈现非线性和非平稳性, 导致其故障特征难以被提取, 故障诊断准确率低。针对上述问题, 文章提出一种基于多尺度样本熵改进极限学习机的列车转向架轴承故障诊断方法。其首先利用多尺度样本熵提取故障特征, 构成特征向量集; 然后利用粒子群算法优化极限学习机, 得到输入权值和隐含节点阈值; 最后, 将特征向量集划分为测试集和训练集, 利用改进的极限学习机作为模式识别算法进行故障模式识别。实验结果表明, 本文提出的方法能够有效地进行故障模式识别, 识别准确率达到 96%, 适用于列车轴承故障诊断。

关键词: 多尺度样本熵; 特征提取; 故障诊断; 改进极限学习机; 转向架轴承

中图分类号: TP277; U260.331⁺.2 文献标识码: A 文章编号: 2096-5427(2021)05-0066-05

doi:10.13889/j.issn.2096-5427.2021.05.011

Fault Diagnosis of Train Bogie Bearing Based on Multi-scale Sample Entropy Improved Extreme Learning Machine

JIN Zhenzhen¹, HE Deqiang¹, MIAO Jian¹, XU Weichang²

(1. College of Mechanical Engineering, Guangxi University, Nanning, Guangxi 530004, China;

2. Nanning CRRC Rail Transit Equipment Co., Ltd., Nanning, Guangxi 530000, China)

Abstract: Train bogie bearing is affected by track excitation, uncertainty of running speed, impact vibration of track joints and vibration of other components. The vibration signal is nonlinear and non-stationary, which makes it difficult to extract fault characteristics and fault diagnosis accuracy is low. In view of above problems, a fault diagnosis method of train bogie bearing based on multi-scale sample entropy improved extreme learning machine is proposed. Firstly, fault features are extracted by using the multi-scale sample entropy to form a feature vector set. Then, the extreme learning machine is optimized by particle swarm optimization, and the input weights and hidden node thresholds are obtained. Finally, the feature vector set is divided into test set and training set, and the improved extreme learning machine is used as a pattern recognition algorithm for fault pattern recognition. Experimental results show that the proposed method can effectively carry out fault pattern recognition, and the recognition accuracy reaches 96 %, which is suitable for train bearing fault diagnosis.

Keywords: multi-scale sample entropy; feature extraction; fault diagnosis; improved extreme learning machine; bogie bearing

收稿日期: 2021-07-09

作者简介: 靳震震 (1994—), 男, 博士研究生, 研究方向为列车智能运维;

贺德强 (1973—), 男, 教授, 博士, 博士生导师, 主要从事列车故障诊断与智能维护。

基金项目: 国家自然科学基金项目 (52072081); 广西自然科学基金重点项目 (2017GXNSFDA198012); 广西创新驱动发展专项 (桂科 AA20302010)

0 引言

随着轨道交通行业的不断发展及列车运行速度的不断提高,铁路的运载量在不断增大,给列车安全运行带来严峻的挑战。列车转向架长期在重载工况下持续运转,且运行环境不断变化,增加了轴承故障发生的概率^[1]。及时掌握轴承运转状态、有效进行轴承故障诊断,这对保障列车安全健康运行具有重要意义。基于振动信号进行分析是目前轴承故障诊断常用的方法^[2],现有使用技术中,时域和频域信号分析方法虽然能够进行故障诊断,但是时域信号分析方法不能够准确判断出哪个元件出现故障;而频域信号分析方法不能体现故障发生的时刻。此外,轨道激扰、运行速度不确定以及轨道接缝的冲击振动等因素使转向架轴承的振动信号呈现非线性和非平稳性,导致转向架轴承的故障特征难以被提取,故障诊断的准确率低下。

信息熵是一种用来评估信号复杂程度的指标。通过信息熵,可以量化振动信号;借助其包含的复杂信息,能够达到特征提取的目的^[3]。样本熵和排列熵作为信息熵的两种形式,已被作为提取特征的主要方式,应用于列车轴承故障诊断领域。文献[4]中,样本熵被用于有效地提取隐藏在转向架振动信号中的故障特征;文献[5]利用排列熵提取了列车滚动轴承振动信号中的故障特征。但是,样本熵和排列熵作为单一尺度的分析方法,并不能完全反应信息的复杂程度;而多尺度样本熵反映了信号在不同尺度下的复杂程度,相比于样本熵和排列熵,其在特征提取方面具有较大的优势。

极限学习机(extreme learning machine, ELM)^[6]是一种单层前馈神经网络,不需要对隐含层参数进行反复调整,相比传统的模式识别算法,其具有速度快和泛化性好的优势,已被作为模式识别算法应用于故障诊断领域。文献[7]将 ELM 作为齿轮故障模式识别方法,通过实验验证了方法的有效性。文献[8]将得到的特征向量输入到 ELM 以识别柱塞泵故障模式,实验结果表明,ELM 相比支持向量机在分类速度和精度上的优势更加明显。但 ELM 也存在一定的局限性,其分类精度与输入的权值、隐含层节点阈值密切相关。粒子群优化算法(particle swarm optimization, PSO)是一种应用较为广泛的算法,具有精度高、收敛速度快的优点,在解决优化问题方面具有一定优势。因此,本文将粒子群算法与 ELM 相结合,利用 PSO 算法解决 ELM 参数设置问题。

基于上述分析,针对列车转向架轴承故障诊断率低的问题,本文提出一种基于多尺度样本熵改进 ELM 的列车转向架轴承故障诊断方法,实验结果表明,本文提出的方法能够有效提取故障特征信息,准确实现轴承故障模式的识别。

1 多尺度样本熵

样本熵确定的是单一尺度熵信号的复杂程度,熵值越大,信号越复杂。多尺度样本熵是通过粗粒化过程获得的,其计算步骤如下:

(1) 对长度为 K 的时间序列 $F=\{f_1=1, 2, \dots, K\}$ 进行粗粒化处理,得到粗粒化序列 $z_{j,s}$,具体如式(1)所示。

$$z_{j,s} = \frac{1}{s} \sum_{i=(j-1)s+1}^{js} f_i, j=1, 2, \dots, [K/s] \quad (1)$$

式中: j ——粗粒化序列长度; s ——尺度因子, $s=1, 2, \dots, [K/s]$ 。其中, $[K/s]$ 表示 K/s 取整。

(2) 计算不同尺度因子 s 下粗粒化序列 $z_{j,s}$ 的样本熵值,可得多尺度样本熵,如式(2)所示。

$$E_{\text{MSE}}(f, s, p, r) = E_{\text{SE}}(z_s, p, r) = -\ln(o_{s,(p+1)} / o_{s,p}) \quad (2)$$

式中: f ——原始信号; p ——嵌入维数; r ——相似容限; $E_{\text{SE}}(z_s, p, r)$ ——样本熵值; $o_{s,(p+1)}$, $o_{s,p}$ ——粗粒化序列的 $(p+1)$ 维、 p 维空间向量个数。

2 改进极限学习机

极限学习机是一种性能优良的神经网络算法,其可以随机初始化输入权值和隐含层阈值,利用广义逆矩阵理论仅通过一步计算即可得到相应的网络输出权值。设 ELM 网络有 m 个输入神经元、 L 个隐含层神经元和 n 个输出层神经元,其网络结构如图 1 所示。




图 1 ELM 结构图

Fig. 1 ELM structure diagram

假定有 N 个训练样本集 $(x_i, y_i), 1 \leq i \leq N$, 其中, $x_i \in R^m, y_i \in R^n$ 。图 1 中, 输入层的 m 个神经元与输出层的 n 个神经元分别对应 m 个输入变量和 n 个输出变量, 则网络输出可表示为

$$\sum_{j=1}^L \beta_j G(w_j x_i + b_j) = o_i \tag{3}$$

式中: w_j ——输入权值向量; b_j ——隐含层节点阈值; β_j ——输出权值向量; $G(x)$ ——激活函数; o_i ——网络输出值。

虽然 ELM 具有较好的分类精度, 但其性能受到输入的权值和隐含层阈值的影响。为解决 ELM 存在的问题, 将 PSO 算法与 ELM 相结合, 利用 PSO 算法对 ELM 参数进行优化, 将 ELM 的输入权值 ω 和隐含层节点阈值 b 作为 PSO 算法中的粒子群, 并将训练样本的方均根误差作为粒子群的适应度值, 以方均根最小为优化目标进行 ELM 参数优化, 具体过程如图 2 所示。




图 2 PSO-ELM 流程
Fig. 2 PSO-ELM process

3 实验验证

轴承故障诊断过程主要包括数据采集、特征提取和模式识别 3 个部分。首先, 采集轴承的振动信号; 然后, 利用多尺度样本熵进行特征提取, 并将提取的特征划分为测试集和训练集; 最后, 利用改进的 ELM 进行故障模式识别。

3.1 数据采集

实验数据来源于美国凯斯西储大学实验平台采集的数据。该实验平台结构如图 3 所示, 设备包括电机、转矩传感器和电子控制设备等, 试验轴承型号为 SKF62。

本文采用的数据为采样频率 12 kHz 下驱动端轴承故障数据, 涉及正常、内圈故障、外圈故障和滚动体故障 4 种状态, 每种状态采集 50 个样本, 每个样本点数为 2 048 个数据点, 原始信号的时域波形如图 4 所示。从图中可以看出, 内圈和外圈信号出现了显著的冲击, 滚动体故障冲击不明显, 无法通过时域信号准确地判断出哪个部件出现了故障。




图 3 数据采集试验台
Fig. 3 Experimental data acquisition platform




图 4 原始振动信号时域波形图
Fig. 4 Time-domain waveforms of original vibration signal

3.2 特征提取

利用多尺度样本熵提取轴承 4 种状态下的特征信息, 设置多尺度样本熵的参数相似容限 $r=0.5 \text{ std}(\text{data})$, 其中 $\text{std}(\text{data})$ 为样本数据的标准差。尺

度因子 s 过大, 会影响诊断效率; 过小, 则无法完全表征特征信息。为确定尺度因子的值, 本文首先设置 $s=20$ 。当尺度因子取 20 时, 分别计算 4 种状态的多尺度样本熵值, 结果如图 5 所示。可以看出, 在尺度因子为 9~20 时, 多尺度样本熵值下降平缓, 变化范围不超过 0.05, 信号之间的复杂程度差异较小。为更好地表征特征信息, 本文选择尺度因子为 8 时的多尺度熵值。




图 5 4 种状态的多尺度样本熵值
Fig. 5 Multi-scale sample entropy values of four states

3.3 模式识别

模式识别的本质是分类问题, 本文采用改进的极限学习机作为模式识别算法。首先, 将 200 组样本数据打乱, 随机选择其中的 150 组作为训练样本, 剩余的数据作为测试样本。然后, 利用 PSO 算法对极限学习机参数进行优化, 设置种群规模为 30, 最大速度为 0.2, 惯性因子起始值为 0.8, 惯性因子终止值为 0.1, 种群迭代次数为 100, 学习因子 C_1 为 2.4, 学习因子 C_2 为 1.6, 寻优结果如图 6 所示。




图 6 寻优迭代图
Fig. 6 Diagram of optimization iteration

从图 6 中可以看出, 在第 8 代时算法达到最优, 此时适应度值为 0.42, 说明 PSO 算法在优化 ELM 参数方面具有精度高和寻优速度快的优势, 适合用于 ELM 参数优化。此时对应的测试集准确率为 96%, 混淆矩阵如图 7 所示。



图 7 混淆矩阵
Fig. 7 Confusion matrix

图 7 中 1, 2, 3, 4 分别对应轴承的外圈故障状态、内圈故障状态、滚动体故障状态、正常状态。可以看出, 本文所提方法对外圈故障状态和正常状态的识别率为 100%, 内圈故障状态和滚动体故障状态的识别率分别为 90.9% 和 92.3%。通过图 5 可知, 内圈故障和滚动体故障的振动信号在平稳和冲击时均存在一定的相似性, 表明这两种状态的特征存在一定的相似性, 因此导致故障模式识别过程出现误判。但是总的来说, 测试集的准确率达到 96%, 说明本文提出的方法在一定程度上能够有效地进行故障模式识别, 同时验证了多尺度样本熵在轴承特征提取方面的可行性。

为进一步验证本文提出方法的有效性, 采用未优化的极限学习和支持向量机进行对比, 并采用样本熵作为特征提取方法进行对比, 故障诊断准确率如表 1 所示。

表 1 故障诊断方法对比
Tab. 1 Comparison among fault diagnosis methods

序号	方法	准确率
1	多尺度样本熵 - 极限学习机	92%
2	多尺度样本熵 - 支持向量机	90%
3	样本熵 - 改进极限学习机	90%
4	多尺度样本熵 - 改进极限学习机	96%

由表 1 可以看出, 采用未优化的极限学习机进行模式识别时准确率为 92%, 高于支持向量机作为模式识别算法的 (90%), 但低于本文提出的改进极限学习机方法的。识别准确率表明极限学习机在模式识别方面具有一定的优越性, 同时验证了本文提出方法的有效性。采用样本熵进行特征提取, 将提取的特征向量输入到改进的极限学习机中, 故障诊断准确率为

90%，低于本文提出的方法。通过对比可知，多尺度样本熵能够提取有用故障特征信息，适用于轴承故障特征提取。综合上述分析可知，本文提出的方法能够有效进行轴承故障模式识别，准确率高，适用于列车转向架轴承故障诊断。

4 结语

列车转向架轴承振动信号的非线性和非平稳性致使故障特征难以被提取，故障诊断准确率低。对此，本文提出一种基于多尺度样本熵改进极限学习机（PSO-ELM）的列车转向架轴承故障诊断方法，其采用多尺度样本熵作为特征提取方法，能够有效提取故障特征，优于单一尺度熵的特征提取方法；PSO-ELM方法在轴承故障模式识别方面准确率高，作为模式识别方法具有较大优势。实验结果表明，本文提出的基于多尺度样本熵改进极限学习机的列车转向架轴承故障诊断方法具有良好的可行性。

由于列车在实际运行中产生的故障数据集较少，而正常数据集较多，造成了数据不均衡的情况。因此，下一步将考虑开展数据不均衡情况下列车轴承故障的诊断研究。

参考文献：

- [1] 贺德强, 张焕, 孙一, 等. 基于预紧量变化的列车牵引电机轴承寿命预测方法 [J]. 机车电传动, 2018(5):29-33.
HE D Q, ZHANG H, SUN Y, et al. Prediction method of bearing life of train traction motor based on preload variation [J]. Electric Drive for Locomotives, 2018(5): 29-33.
- [2] 李笑梅, 贺德强, 谭文举, 等. 基于 EEMD 和 RBFNN 的列车滚动轴承故障诊断研究 [J]. 铁道科学与工程学报, 2017, 14(5): 1056-1062.
LI X M, HE D Q, TAN W J, et al. Research on fault diagnosis of train rolling bearing based on EEMD and RBFNN[J]. Journal of Railway Science and Engineering, 2017, 14(5): 1056-1062.
- [3] 乔新勇, 顾程, 韩立军. 基于 VMD 多尺度散布熵的柴油机故障诊断方法 [J]. 汽车工程, 2020,42(8):1139-1144.
QIAO X Y, GU C, HAN L J. Diesel Engine Fault Diagnosis Method Based on VMD and Multi-Scale Dispersion Entropy [J]. Automotive Engineering, 2020,42(8):1139-1144.
- [4] 秦娜, 金炜东, 黄进, 等. 基于 EEMD 样本熵的高速列车转向架故障特征提取 [J]. 西南交通大学学报, 2014, 49(1): 27-32.
QIN N, JIN W D, HUANG J, et al. Feature extraction of high speed train bogie based on ensemble empirical mode decomposition and sample entropy[J]. Journal of Southwest Jiaotong University, 2014,49(1):27-32.
- [5] 冯波. 基于 SVD-PE 的高速列车滚动轴承故障诊断模型 [J]. 组合机床与自动化加工技术, 2018(7): 108-110, 114.
FENG B. Fault diagnosis of rolling bearing of high speed train based on SVD-PE[J]. Modular Machine Tool & Automatic Manufacturing Technique, 2018(7): 108-110, 114.
- [6] 戴伯望, 赵香桂, 朱淇凉. 基于改进 BP-SVM-ELM 组合预测的光伏 MPPT 方法研究 [J]. 控制与信息技术, 2019(1): 44-49, 63.
DAI B W, ZHAO X G, ZHU Q L. Research on the photovoltaic MPPT method based on improved BP-SVM-ELM combination prediction[J]. Control and Information Technology, 2019(1): 44-49, 63.
- [7] 张宁, 魏秀业, 徐晋宏. 基于 LMD 样本熵与 ELM 的行星齿轮箱故障诊断 [J]. 机械传动, 2020, 44(4): 152-157.
ZHANG N, WEI X Y, XU J H. Planetary gearbox fault diagnosis based on LMD sample entropy and ELM [J]. Journal of Mechanical Transmission, 2020, 44(4): 152-157.
- [8] 程珩, 励文艳, 权龙, 等. 基于 VMD-MDE 和 ELM 的柱塞泵微弱故障诊断 [J]. 振动. 测试与诊断, 2020, 40(4): 635-642, 818.
CHENG H, LI W Y, QUAN L, et al. Weak Fault Diagnosis of Axial Piston Pump Based on VMD-MDE and ELM[J]. Journal of Vibration Measurement & Diagnosis, 2020, 40(4): 635-642, 818.