

基于双向长短时记忆网络的牵引机齿轮泵故障诊断

王长华¹, 蒋云刚^{2,3}, 李保¹, 吴珂², 朱凯⁴

(1. 浙江省机电设计研究院有限公司, 浙江 杭州 310051; 2. 浙江大学 平衡建筑研究中心, 浙江 杭州 310007;
3. 杭州运河集团建设管理有限公司, 浙江 杭州 310000; 4. 中国计量大学 质量与安全工程学院, 浙江 杭州 310018)

摘要:为了提高电梯牵引机齿轮泵的典型故障诊断精度,提出一种基于经验模态分解(EEMD)和双向长短时记忆网络(BLSTM)的行星齿轮泵故障诊断方法。总共设置4种行星齿轮故障类型,综合验证检测性能。通过EEMD方法完成信号分解,对网络实施训练来提升故障类型的分辨精度。研究结果表明:本故障诊断网络模型损失<1%,具有良好稳定性。断齿、正常齿的轮识别率都达到了93%以上,齿根裂纹故障识别率达到了87.2%,可以实现精确识别齿面故障。经过EEMD处理的网络稳定性与精度显著提升。到达后期迭代阶段时,BLSTM网络拟合速度开始变快,精度也获得提升。

关键词:齿轮泵;故障诊断;经验模态分解;双向长短时记忆网络;分类精度

中图分类号:TH137 **文献标志码:**A **文章编号:**1671-5276(2022)03-0057-04

Fault Diagnosis of Tractor Gear Pump Based on Bi-directional Short and Long Time Memory Network

WANG Changhua¹, JIANG Yungang^{2,3}, LI Bao¹, WU Ke², ZHU Kai⁴

(1. Zhejiang Institute of Mechanical and Electrical Engineering Co., Ltd., Hangzhou 310051, China;
2. Center for Balance Architecture, Zhejiang University, Hangzhou 310007, China;
3. Hangzhou Canal Group Construction Management Co., Ltd., Hangzhou 310000, China;
4. College of Quality and Safety Engineering, China Metrology University, Hangzhou 310018, China)

Abstract: To improve the typical fault diagnosis accuracy of elevator tractor gear pump, a fault diagnosis method of planetary gear pump based on ensemble empirical mode decomposition (EEMD) and bidirectional short and long time memory network (BLSTM) is proposed. Four kinds of planetary gear fault types are set up to verify comprehensively the detection performance. EEMD method is used to complete signal decomposition, and network training is carried out to improve the resolution accuracy of fault types. The results show that the loss of the fault diagnosis network model is less than 1% and has good stability. The wheel recognition rate of broken teeth and normal teeth is more than 93%, and the tooth root crack fault is 87.2%, which can accurately identify tooth surface fault. After EEMD processing, the network stability and accuracy are significantly improved. At the later iteration stage, the BLSTM network fitting speed becomes faster with higher accuracy.

Keywords: gear pump; fault diagnosis; ensemble empirical mode decomposition; bi-directional long short-time memory; classification accuracy

0 引言

随着自动控制的快速发展,工业物联网也获得了广泛应用,可以高效收集大量的牵引设备运行故障,但无法继续通过传统故障分析方法来处理这种大数据故障信息^[1-4]。采用深度学习方法因具备数据自我迭代处理及对多种复杂数据都能够达到快速准确提取的效果,这使其成为大数据处理领域的一项重要应用技术,已被用于语音信号处理、图像分析等方面^[5-8]。石鑫等^[9]选择深度自编码网络诊断电力变压器的运行故障;王惠中等^[10]则根

据LSTM方法在时间序列提取的独特优势,综合运用LSTM与Softmax分类器方法对各类故障信号进行诊断分析。

国内学者胡芑庆等^[11]也开展了智能诊断方面的研究工作,利用经验模态分解方法度数据进行处理,再通过深度卷积神经网络达到诊断的要求。步骤是先对信号实施EMD处理完成分解过程,将其转换成多个IMF分量后计算每个分量的峭度,再以DCNN对其中峭度较大的6个分量进行特征融合,接着继续测定行星齿轮泵齿的振动信号并验证了该方法实际诊断效果。WU C Z等^[12]则利用一维卷积神经网络来判断齿轮箱形成的振动信号,结果发现

基金项目:国家重点研发计划项目(2021YFF0602201),浙江省重点研发项目(2018C03029)

第一作者简介:王长华(1978—),男,浙江临海人,高级工程师,本科,主要从事机电设计工作。

通信作者简介:朱凯(1988—),男,江苏苏州人,副教授,博士,研究方向为交通安全与可靠性。

该诊断方法能够达到高精度的判断要求。本文测试在行星齿轮泵故障诊断前进行,采用经验模态分解(ensemble empirical mode decomposition, EEMD)和双向记忆网络(bi-directional long short-time memory, BLSTM)相结合的模式,对本实验中4种不同的齿轮泵进行故障测试。采用EEMD方法实施信号分解生成相应的IMF分量,将上述参数输入模型内进行训练得到准确的分类结果。

1 双向长短时记忆网络

1.1 循环神经网络

循环神经网络(recurrent neural network, RNN)属于一类递归神经网络,时间序列输出取决于前一时间步与当前输入的共同影响。

t 时刻的RNN网络输出为:

$$s_t = f(ux_t + ws_{t-1}) \quad (1)$$

$$y_t = g(vs_t) \quad (2)$$

式中: $t-1$ 是上个时刻; t 是现有时刻; w 为之前隐藏层相对目前隐藏层所占的权重; x 为RNN网络输入; u 表示输入层至隐藏层权重; y 为RNN网络预测结果; s 为隐藏层状态输出。

以 E 表示网络在 t 时的总损失,如式(13)所示。

$$E = \sum_t -\hat{y}_t \log y_t \quad (3)$$

对网络进行训练时通过参数优化算法来完成 u 、 w 、 v 参数的更新。式(4)给出了参数 w 在 t 时梯度误差计算式。

$$\frac{\partial E_t}{\partial w} = \sum_{k=0}^t \frac{\partial E_t}{\partial y_k} \cdot \frac{\partial y_k}{\partial s_t} \cdot \frac{\partial s_t}{\partial s_k} \cdot \frac{\partial s_k}{\partial w} \quad (4)$$

在处理深层次网络的时候,当选择参数优化模式实施更新时,将会出现局部梯度弥散的结果,严重时还会引起梯度爆炸,从而导致产生差异很大的网络权重,表现为网络状态的大幅波动。

1.2 双向长短时记忆网络

为得到更加准确的信息,构建得到双向长短时记忆网络,图1显示了BLSTM通过时间展开计算的结果。




图1 BLSTM网络结构

显然,当前输出受到前向层和反向层输出综合作用,式(5)-式(7)给出了网络在 t 时的输出 o_t 。

$$\vec{h}_t = f(w_1 x_t + w_2 \vec{h}_{t-1}) \quad (5)$$

$$\overleftarrow{h}_t = f(w_3 x_t + w_5 \overleftarrow{h}_{t+1}) \quad (6)$$

$$o_t = g(w_4 \vec{h}_t + w_6 \overleftarrow{h}_t) \quad (7)$$

式中: w 为权重; h_t 为正向隐藏层输出; \rightarrow 为网络正向输入; \leftarrow 为网络反向输入。

2 数据处理及网络设置

2.1 数据集描述

齿轮泵测试平台如图2所示。分别对齿轮泵处于不同的运行状态下形成的信号数据进行采集分析,采集的齿轮泵4种故障数据集描述如表1所示,齿轮泵故障时域图如图3所示。本实验将采样频率设定在10kHz,电机转速2500r/min,依次对各齿轮状态采集得到300组振动加速度信号,每组中存在900点数据。




图2 现场测试图片

表1 齿轮泵4种故障数据集描述

标签	齿轮泵健康状态	样本数量
1	正常	500
2	齿根裂纹	500
3	齿面磨损	500
4	断齿	500

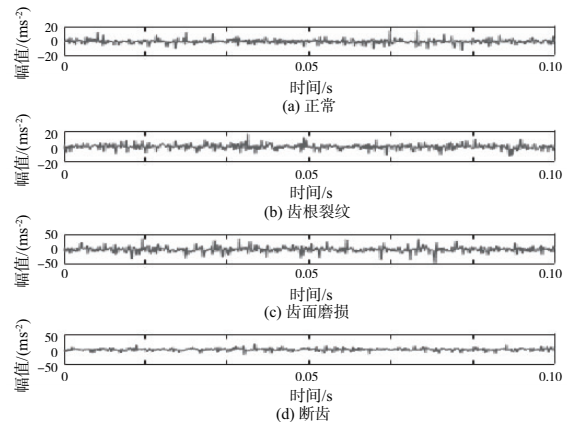


图3 齿轮泵故障时域图

2.2 EEMD分解

对本实验采集得到的初始数据进行EEMD分解获得IMF分量,再以频率由高往低的顺序排序后,将高斯白噪声加入,其标准偏差为0.2,迭代次数上限为25,后续分量信息造成的影响可以忽略。本次共确定6个IMF分量,对齿轮不同运行状态下的信号实施分解,结果见图4。




图4 不同故障的 EEMD 分解

利用 BLSTM 网络对初始 6 个模态分量识别,进行模型训练时,由于分量包含了太长的数据,需要花费更长时间才能完成训练。为提升训练效率并改善精度,选择 15 个时域和 16 个频域特征进行分析,再将模型输入维度由 1 000 降低至 30,进一步优化了故障特征。

2.3 参数设置

本研究构建的双向长短时记忆模型包含了 1 个 Softmax 层、1 个全连接层、1 个分类输出层、1 个 BLSTM 层。为全连接层设置了 Dropout 随机失活层,避免模型发生过拟合的问题,控制失活值保持在恒定的 0.65,并设置更多 ReLU 激活层来达到加快网络训练的效果。本次模型运行环境为 Matlab2019a,具体参数见表 2。

表 2 BLSTM 网络

层数	类型	参数
1	序列输入层	30×8×1
2	BLSTM	100
3	Dropout 层	0.68
4	ReLU 层	6
5	全连接层	6
6	Softmax 层	6
7	分类输出层	6

测试时设定批量为 100,学习率 0.01,选择 Adam 算法完成寻优计算。通过控制梯度阈值=1 以防止梯度爆炸的情况;以轮数代表训练次数,共训练 50 次,每个周期结束后再对网络开展 1 次迭代计算。表 3 为本实验的网络超参数。

表 3 BLSTM 网络超参数设置

超参数	值
批量大小	100
学习率	0.01
梯度阈值	1
最大迭代轮数	50
验证频率	50

3 实物实验结果分析

3.1 实验结果

以上述实验实测获得信号处理后数据为研究对象,随机选择比例为 80% 的数据实施训练,再测试剩余 30% 比例的数据。图 5 给出了模型训练与验证过程,可以看到在不同迭代次数下验证误差变化情况。通过测试发现该模型精度达到 95.3%,进行迭代计算时形成了波动变化的训练曲线,可以推断该模型并没有达到稳定预测的效果。以图 6 的混淆矩阵模型准确识别齿面形成的磨损缺陷和缺齿情况,断齿识别率 94.1%,最低的是齿根裂纹故障识别率,只达到 86.5%。同时发现齿根裂纹只达到了一个较低的识别率,这是由于齿根裂纹会被误判为断齿而引起结果偏差。




图 5 BLSTM 网络训练损失随迭代次数的变化

1	139	2		1	2	96.5%	3.5%
2	2	140		2		97.2%	2.8%
3			142	1	1	98.6%	1.4%
4	1	2	1	137	3	95.1%	4.9%
5	1				143	99.3%	0.7%
	97.2%	97.2%	99.3%	97.2%	96.0%		
	2.8%	2.8%	0.7%	2.8%	4.0%		
	1	2	3	4	5		

图 6 BLSTM 网络验证数据混淆矩阵

3.2 对比分析

图 7 显示了未进行 EEMD 处理和经过 EEMD 处理的两种不同模型对应的迭代精度。可以看到,未经 EEMD

处理的模型表现出了不稳定的测试结果,实际精度只有70%,EEMD处理后模型精度与稳定性都发生了大幅上升。因此,BLSTM模型在时序信号处理方面具有明显优势,本次测试的初始信号呈现相对紊乱的时序特性,不能达到准确识别的效果。先对信号EEMD分解后,可以促进所有分量都获得更优的时序性,促使模型诊断精度得到显著提升。




图7 EEMD处理前后网络精度随迭代次数的变化

4 结语

1) 本网络损失 $<1\%$,可以推断该网络满足良好稳定性的条件,可以实现精确识别齿面磨损和缺齿的问题,断齿、正常齿的轮识别率都达到了93%以上,齿根裂纹故障识别率达到了87.2%。

2) 经过EEMD处理的网络稳定性与精度显著提升。到达后期迭代阶段时,BLSTM网络拟合速度开始变快,精度也获得提升。

参考文献:

[1] 姜万录,李振宝,张生,等. 基于递归定量分析的液压泵故障识别方法[J]. 液压与气动,2019(2):18-23.

- [2] CHEN J L,LI Z P,PAN J,et al. Wavelet transform based on inner product in fault diagnosis of rotating machinery: a review[J]. Mechanical Systems and Signal Processing,2016,70/71:1-35.
- [3] WEI Z X,WANG Y X,HE S L,et al. A novel intelligent method for bearing fault diagnosis based on affinity propagation clustering and adaptive feature selection[J]. Knowledge-Based Systems, 2017,116:1-12.
- [4] 励文艳,程珩,赵立红,等. 基于局部s变换和极限学习机的柱塞泵滑靴磨损故障诊断[J]. 液压与气动,2019(12):15-21.
- [5] MAHMOODIAN N,SCHAUFLE A,PASHAZADEH A, et al. Proximal detection of guide wire perforation using feature extraction from bispectral audio signal analysis combined with machine learning[J]. Computers in Biology and Medicine,2019,107:10-17.
- [6] 程秀芳,王鹏. 基于时域和频域分析的滚动轴承故障诊断[J]. 华北理工大学学报(自然科学版),2020,42(1):58-64.
- [7] 蔡改贫,宗路,刘鑫,等. 基于MEEMD-多尺度分形盒维数和ELM的球磨机负荷识别方法[J]. 化工学报,2019,70(2):764-771.
- [8] CHEN D Y,LIN J H,LI Y P. Modified complementary ensemble empirical mode decomposition and intrinsic mode functions evaluation index for high-speed train gearbox fault diagnosis[J]. Journal of Sound and Vibration,2018,424:192-207.
- [9] 石鑫,朱永利,宁晓光,等. 基于深度自编码网络的电力变压器故障诊断[J]. 电力自动化设备,2016,36(5):122-126.
- [10] 王惠中,贺珂珂,房理想. 长短时记忆网络在电机故障诊断中的应用研究[J]. 自动化仪表,2019,40(1):6-10.
- [11] 胡芑庆,陈徽鹏,程哲,等. 基于经验模态分解和深度卷积神经网络的行星齿轮箱故障诊断方法[J]. 机械工程学报,2019,55(7):9-18.
- [12] WU C Z,JIANG P C,DING C,et al. Intelligent fault diagnosis of rotating machinery based on one-dimensional convolutional neural network[J]. Computers in Industry,2019,108:53-61.

收稿日期:2021-12-01

(上接第56页)

[13] 叶鑫,安鲁陵,岳烜德,等. 间隙与垫片补偿下复材-铝合金结构表面应变的研究[J]. 机械制造与自动化,2020,49(6):18-20,35.

[14] 叶鑫,安鲁陵,岳烜德,等. 液体垫片对复材-铝单搭接接头拉伸性能的影响[J]. 机械制造与自动化,2021,50(1):21-24,28.

[15] MOTOSH N. Development of design charts for bolts preloaded up to the plastic range[J]. Journal of Engineering for Industry, 1976,98(3):849-851.

[16] VDI 2230 Systematic calculation of bolted joints[S].

[17] ISO 16047 Fasteners-torque/clamp force testing[S].

- [18] ASTM D5961/D5961M Standard test method for bearing response of polymer matrix composite laminates[S].
- [19] 张和平,闫毓卿,莫易敏. 锁紧螺母转矩设计与重复使用特性研究[J]. 机械设计与制造,2018(S1):114-116,120.
- [20] 王晓斌,蒋佳桢,陈平,等. 拧紧转速对螺栓联接可靠性分析[J]. 机电工程技术,2016,45(3):101-104.
- [21] HYER M W,KLANG E C,COOPER D E. The effects of pin elasticity,clearance,and friction on the stresses in a pin-loaded orthotropic plate[J]. Journal of Composite Materials, 1987,21(3):190-206.

收稿日期:2021-03-08