

doi:10.3969/j.issn.1673-9833.2020.04.006

基于神经网络和证据理论的滚动轴承故障预测方法

李泓洋^{1,2}, 万烂军^{1,2}, 李长云^{1,2}, 陈意伟^{1,2}

(1. 湖南工业大学 计算机学院, 湖南 株洲 412007;

2. 湖南工业大学 智能信息感知及处理技术湖南省重点实验室, 湖南 株洲 412007)

摘要: 传统的故障预测方法难以对不同工况下的滚动轴承故障进行有效预测, 为此, 提出了一种基于BP神经网络和DS证据理论的滚动轴承故障预测方法。首先采用擅长于处理非平稳信号的小波包分解对多个传感器采集的原始振动数据进行特征分析, 然后对BP神经网络的结构和参数进行优化设置并使用多个BP神经网络分别进行故障预测模型训练, 最后利用DS证据理论将多个神经网络得到的预测结果进行融合并输出最终预测结果。实验结果表明, 该方法能对不同工况下的滚动轴承故障进行有效预测, 故障预测平均准确率达96.37%; 且与相关文献提出的方法相比, 所提出的方法得到的滚动轴承故障预测准确率有所提升。

关键词: 滚动轴承; 故障预测; BP神经网络; DS证据理论; 小波包分解

中图分类号: TH133.33 **文献标志码:** A **文章编号:** 1673-9833(2020)04-0035-07

引文格式: 李泓洋, 万烂军, 李长云, 等. 基于神经网络和证据理论的滚动轴承故障预测方法[J]. 湖南工业大学学报, 2020, 34(4): 35-41.

A Rolling Bearing Fault Prediction Method Based on Neural Network and Evidence Theory

LI Hongyang^{1,2}, WAN Lanjun^{1,2}, LI Changyun^{1,2}, CHEN Yiwei^{1,2}

(1. College of Computer Science, Hunan University of Technology, Zhuzhou Hunan 412007, China;

2. Hunan Key Laboratory of Intelligent Information Perception and Processing Technology, Hunan University of Technology, Zhuzhou Hunan 412007, China)

Abstract: In view of the low efficiency found in the traditional fault prediction methods to predict rolling bearing faults under different working conditions, a new fault prediction method of rolling bearing based on BP neural network and DS evidence theory has thus been proposed. Firstly the wavelet packet decomposition, which is good at processing non-stationary signals, is used to analyze the characteristics of the original vibration data collected by multiple sensors. Next, the structure and parameters of BP neural network are optimized, with multiple BP neural networks used to train the fault prediction model respectively. And finally, the DS evidence theory is used to fuse the prediction results obtained by the multiple neural networks with the final prediction result output. The experimental results show that the proposed method can effectively predict the fault of rolling bearing under different working conditions, with the average accuracy of fault prediction attaining 96.37%. Compared with the methods proposed in the related literature,

收稿日期: 2019-12-25

基金项目: 国家自然科学基金资助项目(61702177), 湖南省教育厅开放平台创新基金资助项目(17K029), 湖南省自然科学基金资助项目(2019JJ60048), 国家重点研发计划基金资助项目(2018YFB1700200, 2018YFB1003401), 湖南省重点研发计划基金资助项目(2019GK2133)

作者简介: 李泓洋(1995-), 男, 黑龙江大庆人, 湖南工业大学硕士生, 主要研究方向为工业大数据,
E-mail: lhy461040892@gmail.com

通信作者: 万烂军(1982-), 男, 湖南岳阳人, 湖南工业大学讲师, 博士, 硕士生导师, 主要从事工业大数据与并行计算方面的教学与研究, E-mail: wanlanjun@hut.edu.cn

the accuracy of the rolling bearing fault prediction obtained by the proposed method has been improved.

Keywords: rolling bearing; fault prediction; BP neural network; DS evidence theory; wavelet packet decomposition

0 引言

滚动轴承是否正常运行往往直接影响到整个旋转机械设备, 据统计, 30% 旋转机械设备故障是由滚动轴承故障引起的, 由此可见, 滚轴故障预测对保证整个设备的安全有效运行至关重要^[1-4]。近年来, 在轴承故障诊断方面已有较多的研究成果^[5-12], 不少学者采用不同方法对滚动轴承故障进行了有效诊断。如唐贵基等^[5]针对轴承振动信号中存在周期性冲击现象, 将不同故障轴承信号的时间-小波能量谱熵作为向量特征输入, 建立支持向量机, 实现了对轴承的工作状态和故障类型的判断。林雅慧等^[6]为了提高 FSVM (fuzzy support vector machines) 的诊断精确度, 采用粒子群优化算法 PSO (particle swarm optimization) 对其进行改进。采用改进的 PSO 和 FSVM 相结合的故障诊断模型在滚动轴承故障诊断领域取得很好的诊断效果。黄良沛等^[7]根据滚动轴承振动信号的不同故障模式在频域能量分布中的差异性, 提出了基于小波包分解与重构和反向传播 (back propagation, BP) 神经网络的轴承故障模式识别技术。并以实验结果证明采用小波包分解与重构和 BP 神经网络相结合的方法可以比较准确地识别滚动轴承的故障。于景洋等^[8]提出利用深度学习中的一维卷积神经网络对滚动轴承进行故障诊断, 并证明该方法具有一定的可行性和有效性。贺思艳等^[9]针对传统故障诊断方法诊断过程复杂、效果不佳的问题, 提出一种基于二维卷积神经网络的滚动轴承故障诊断方法, 该方法可以准确地将滚动轴承的故障进行识别和分类。此外, 李锋等^[10]采用强化学习单元匹配循环神经网络对双列滚子轴承状态趋势进行预测; 曲建岭等^[11]针对现有旋转机械故障诊断过度依赖专家先验知识的问题, 提出了一种基于移不变字典学习和稀疏编码的滚动轴承故障识别算法; Wang J. 等^[12]采用稀疏表示方法, 对大规模风机轴承故障进行了诊断。

在实际生产中, 滚动轴承通常工作在不同工况条件下, 而传统的故障预测方法大多对滚动轴承的工况依赖性较强, 难以对不同工况下的滚动轴承故障进行有效预测, 为此, 本文提出一种能适应不同工况的基于 BP 神经网络和 DS (Dempster-Shafer) 证据理论的滚动轴承故障预测方法, 并采用该方法对西储大学的

滚动轴承数据进行分析, 以验证所提方法的有效性。

1 基本理论

1.1 小波包分解

传统的振动信号处理一般采用傅里叶变换^[1-2], 因其窗口函数的大小和形状固定不变, 故不适合对滚动轴承非平稳振动信号进行处理。小波分析^[2-3]是时间和频率窗都可以改变的时频局部化分析方法, 可以对滚动轴承振动信号进行局部化分析。小波包分解^[2-3]是在小波分析的基础上, 将时频平面划分得更为细致, 根据被分析信号的特征, 自适应选取最佳基函数, 实现了对信号更精确的分析。在实际生产中, 滚动轴承振动信号通常包含大量的噪声, 而小波包分解能有效去噪。

在小波包分解算法中, 定义 P_j^i 为第 j 层小波分解得到的第 i 个小波包 (频段), 则原始信号可以表示为 P_0^1 , 小波包分解的计算过程如式 (1) 和式 (2) 所示, 其中式 (1) 表示近似信号, 式 (2) 表示细节信号。

$$P_{j-1}^{2i-1}(t) = HP_{j-1}^i(t), \quad (1)$$

$$P_j^{2i}(t) = GP_{j-1}^i(t). \quad (2)$$

式 (1) (2) 中: H 为低通滤波器;

G 为高通滤波器。

分解后求得各频段的小波包分解系数, 代表各频段的原始信号和小波基函数的相似程度, 继续计算各频段的能量及其在总能量中的占比, 因不同故障类型信号分解后各频段能量占比不同, 故可用来构建特征向量, 用于后续的故障预测。

1.2 BP 神经网络

BP 神经网络^[13]是一种按照误差逆传播算法训练的多层前馈型神经网络, 在处理滚动轴承一维振动信号时, 相比于目前流行的卷积神经网络与循环神经网络, BP 神经网络的结构更简单, 训练速度更快, 同时具有较强的非线性映射能力、高度自学习能力和自适应能力。

BP 神经网络包括输入层、隐藏层和输出层, 每一层都由若干神经元组成, 各层之间各神经元实现全连接。确定网络结构后, 对网络进行如下训练:

i) 初始化连接权值及阈值, 从网络第一层向后

计算各神经元输出。

ii) 当实际输出和期望输出误差较大时, 需对网络进行校正, 从后向前计算权值和阈值对误差的影响 (即梯度), 由此对各权值和阈值进行修改。

iii) 以上两个过程反复交替, 直到误差趋于极小值时结束。

1.3 DS 证据理论

DS 证据理论^[14-15]是 Bayes 推理的一种扩展, 能满足比 Bayes 推理与经典推理更弱的条件, 因其考虑了总不确定性程度, 故在不确定推理方面具有独特优势。本文将 DS 证据理论应用在滚动轴承故障预测中, 能有效融合多个神经网络的预测结果, 提升故障预测模型的泛化性和预测准确率。

证据理论, 首先要建立识别框架 Θ , 即互不相容事件的完备集合, 然后针对识别框架中的每一个假设都分配基本概率 m , 也叫 *mass* 函数, 并满足条件 (3):

$$\sum_{A \subseteq \Theta} m(A) = 1. \quad (3)$$

再由式 (4) 和式 (5) 继续计算每一个假设的信度函数 *Bel* 和似然函数 *Pl*:

$$Bel(A) = \sum_{B \subseteq A} m(B), \quad (4)$$

$$Pl(A) = \sum_{B \cap A \neq \emptyset} m(B), \quad (5)$$

得到信任区间 $[Bel(A), Pl(A)]$, 这表示对当前假设的确认程度。对于 $\forall A \subseteq \Theta$, 识别框架 Θ 上的有限个 *mass* 函数 m_1, m_2, \dots, m_n 的 Dempster 合成规则如式 (6) 所示, 其中 K 为归一化常数, 其计算公式如式 (7) 所示。

$$(m_1 \oplus m_2 \oplus \dots \oplus m_n)(A) = \frac{1}{K} \sum_{A_1 \cap A_2 \cap \dots \cap A_n} m_1(A_1) m_2(A_2) \dots m_n(A_n), \quad (6)$$

$$K = \sum_{A_1 \cap A_2 \cap \dots \cap A_n \neq \emptyset} m_1(A_1) \times m_2(A_2) \times \dots \times m_n(A_n). \quad (7)$$

由式 (6) 得到组合 *mass* 函数后, 进一步计算组合后的信任区间, 完成证据推理。根据组合 *mass* 函数判断哪种假设是最可能的决策结果, 将满足式 (8) 的 A_1 判定为最终结果。

$$m(A_1) = \max\{m(A_i), A_i \subset \Theta\}. \quad (8)$$

2 故障预测方法的设计与实现

2.1 故障预测流程

本文采用小波包分解、BP 神经网络和 DS 证据理论相结合的方法对滚动轴承故障进行预测, 其流程如图 1 所示。

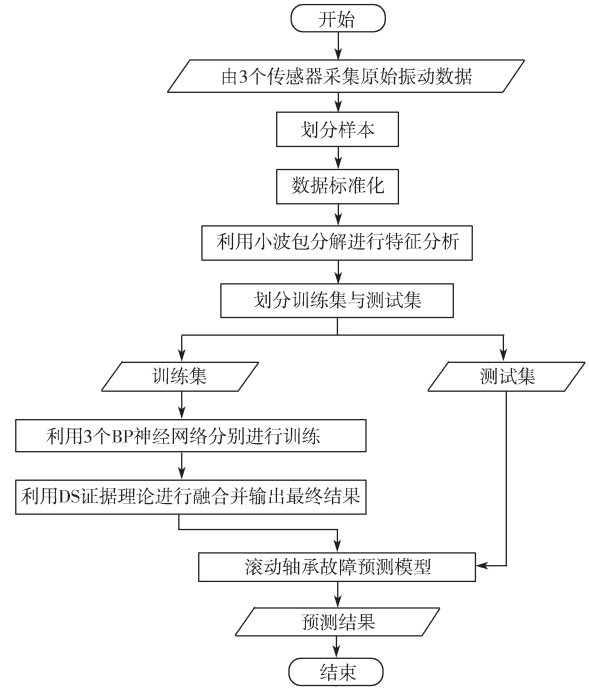


图 1 滚动轴承故障预测流程图

Fig. 1 Flow chart of rolling bearing fault prediction

滚动轴承故障预测主要过程如下: 首先, 采用小波包分解, 对 3 个传感器采集的原始振动数据进行特征分析; 然后, 使用 3 个 BP 神经网络, 分别进行故障预测模型训练; 最后, 利用 DS 证据理论, 将 3 个神经网络得到的预测结果进行融合, 并输出最终预测结果。具体描述如下:

1) 首先, 由部署在电机上的 3 个传感器得到滚动轴承不同状态的原始振动数据; 然后, 根据故障频率选择采样点; 最后, 将统计好的连续数据进行样本划分。

2) 将划分好的样本进行标准化, 这有利于后续神经网络训练的初始化以及收敛速度的提升。

3) 对样本进行小波包分解, 得到各小波包的分解系数, 继续计算各小波包的能量占比, 以此构建滚动轴承不同状态的特征向量。

4) 将特征向量划分为训练集和测试集。

5) 将训练集输入对应的 BP 神经网络, 确定训练参数和网络结构后进行训练, 得到滚动轴承故障分类结果。

6) 利用 DS 证据理论融合 3 个神经网络的输出结果, 并输出最终的故障预测结果, 由此得到滚动轴承故障预测模型。

7) 将测试集作为该故障预测模型的输入, 进行实际的故障预测, 以检验预测效果。

2.2 实验数据选取与预处理

本研究中的实验数据来自于西储大学轴承研究

中心^[16], 包括正常情况下的数据集、12 kHz 和 48 kHz 采样频率下基座端、驱动端以及风扇端的故障数据集, 共有近 1 亿条数据。各故障数据集中包括不同故障直径 (直径为 0.177 8, 0.355 6, 0.533 4, 0.711 2 mm) 和不同电机负载 (0, 0.745 7, 1.491 4, 2.237 1 kW) 情况下的内圈、滚动体、外圈 (依次为 3, 6, 12 点方向) 共 5 种不同类型的故障数据。

本实验选取了正常情况数据集中所有数据以及各故障数据集中故障直径分别为 0.177 8, 0.355 6, 0.533 4 mm (其中 0.711 2 mm 数据量较少), 且电机负载分别为 0, 0.745 7, 1.491 4, 2.237 1 kW 情况下的内圈、滚动体和外圈 6 点方向 (电机负载集中区) 3 种不同类型的故障数据, 共 6 432 万条数据。

在数据预处理中, 首先进行样本划分, 将每 4 000 条数据作为一个样本; 然后对每个样本进行 z-score 标准化, 并根据式 (1) 和式 (2) 进行小波包分解。小波包分解层数的选择不仅会影响特征提取的准确性, 也会影响计算的复杂度, 在本实验中小波包分解层数设置为 3 层, 并选取四阶 Daubechies 小波基函数, 分解后得到 8 个宽度相同的频段。通过计算各频段能量所占比例, 以此构建每个样本的特征向量, 最终得到基座端 1 980 组、驱动端 6 110 组、风扇端 6 110 组特征向量。

不同状态的样本, 经小波包分解后, 得到的各频段能量分布有所差异, 故可作为 BP 神经网络的输入。滚动轴承正常状态与其它 3 种非正常状态 (内圈故障、滚动体故障和外圈故障) 的能量分布明显不同, 但 3 种非正常状态的能量分布较为相似。因此, 直观区分正常状态与非正常状态较为容易, 但是要区分某种故障则难度较大。

2.3 利用 BP 神经网络和 DS 证据理论实现预测

将得到的特征向量划分为训练集与测试集, 不同采样频率、故障直径和电机负载下每种情况取 90% 的数据作为训练集, 剩余 10% 作为测试集。对神经网络进行训练前需设置训练参数并确定网络结构, 用于滚动轴承故障预测的 BP 神经网络参数设置见表 1。

表 1 神经网络参数设置

Table 1 Parameter setting of neural network


参数名称	参数值
隐藏层传递函数	双曲正切函数
训练函数	Levenberg-Marquardt 反向传播算法
学习函数	动量梯度下降权值和阈值学习函数
性能函数	均方误差函数
训练次数	1 000
训练目标最小误差	0.000 1
学习速率	0.003

本实验中使用的 3 个 BP 神经网络, 采用相同的网络结构, 输入层使用 8 个节点, 每个节点对应特征向量中每个频段的能量占比; 根据经验, 隐藏层分别选取 3~17 个节点进行测试, 所得测试结果如表 2 所示。

表 2 不同隐藏层节点数对预测准确率和训练时间的影响
Table 2 Influence of different number of hidden layer nodes on prediction accuracy and training time

隐藏层节点数	训练时间 /s	准确率 /%
3	7	68.81
4	11	70.90
5	14	74.16
6	15	79.20
7	17	81.97
8	18	83.57
9	22	85.88
10	23	88.44
11	28	88.91
12	28	90.90
13	31	90.92
14	33	91.04
15	36	91.10
16	38	91.25
17	42	89.02

综合考虑收敛速度和准确率, 选取最佳隐藏层节点数为 12; 输出层使用 4 个节点, 分别表示 4 种状态 (正常状态、内圈故障、滚动体故障和外圈故障), 最终得到的神经网络结构如图 2 所示。



输入层节点8个 隐藏层节点12个 输出层节点4个

图 2 用于滚动轴承故障预测的 BP 神经网络结构

Fig. 2 BP neural network structure for rolling bearing fault prediction

确定神经网络结构后, 首先, 将训练集中基座端、驱动端、风扇端的特征向量, 分别输入对应的神经网络进行训练, 得到对应的神经网络模型和滚动轴承故障分类结果; 然后, 对分类结果进行验证, 得到对应的混淆矩阵, 如式 (9) 所示, 其表明了神经网络对

不同状态的分类效果。其中, 下标 a 表示对应的神经网络 (a 可取 1, 2, 3, 分别表示基座端、驱动端、风扇端), 各行下标为样本的真实状态, 列下标为神经网络预测的分类结果, 故 cm_{ij} 表示 i 类样本被神经网络判别为 j 类状态的样本数与真实状态为 i 类的样本总数之间的比值。

$$CM_a = \begin{bmatrix} cm_{11} & cm_{12} & cm_{13} & cm_{14} \\ cm_{21} & cm_{22} & cm_{23} & cm_{24} \\ cm_{31} & cm_{32} & cm_{33} & cm_{34} \\ cm_{41} & cm_{42} & cm_{43} & cm_{44} \end{bmatrix} \quad (9)$$

由混淆矩阵可知, 真实状态为 i 类的样本被判别为 j 类状态的概率为 $\omega_{ij}=cm_{ij}$ 。根据式 (10) 计算神经网络模型识别出 j 类状态的局部可信度 ω_{aj} , 根据式 (11) 计算神经网络模型的全局可信度 γ_a 。

$$\omega_{aj} = cm_{ij} / \sum_{i=1}^n cm_{ij}, \quad (10)$$

$$\gamma_a = \frac{1}{n} \sum_{j=1}^n \omega_{aj} \quad (11)$$

将神经网络模型的局部可信度与后验概率输出

p_{aj} 加权融合, 归一化得到 p'_{aj} , 如式 (12) 所示。

$$p'_{aj} = \omega_{aj} p_{aj} / \sum_{j=1}^4 \omega_{aj} p_{aj} \quad (12)$$

计算 3 个神经网络模型的局部可信度和全局可信度, 可根据得到的局部可信度和全局可信度定义基本概率分布函数, 如式 (13) 所示, 其中识别框架为 $\Theta=(A_1, A_2, A_3, A_4, \Theta)$, A_i 表示滚动轴承的 i 类状态。

$$m_a(A_1, A_2, A_3, A_4, \Theta) = (\gamma_a p'_{a1}, \gamma_a p'_{a2}, \gamma_a p'_{a3}, \gamma_a p'_{a4}, 1 - \gamma_a) \quad (13)$$

再根据 Dempster 合成规则, 由式 (6) ~ (8) 可计算出最终的故障分类结果。

3 实验结果及分析

3.1 不同工况下的结果分析

采用测试集对本文的滚动轴承故障预测模型进行验证, 测试集中包含了 24 种不同工况下的测试样本, 表 3 汇总了各工况信息及不同工况下滚动轴承不同类型故障的预测准确率。

表 3 不同工况下滚动轴承不同类型故障的预测准确率

Table 3 Prediction accuracy of different types of rolling bearing faults under different working conditions

工况种类	采样频率 /kHz	故障直径 /mm	电机负载 /kW	准确率 /%			
				内圈故障	滚动体故障	外圈故障	平均值
1	12	0.177 8	0.000 0	98.19	94.90	94.90	95.99
2	12	0.177 8	0.745 7	95.99	98.74	98.74	97.82
3	12	0.177 8	1.491 4	95.45	95.45	98.19	96.36
4	12	0.177 8	2.237 1	97.64	98.74	95.45	97.28
5	12	0.355 6	0.000 0	96.55	98.74	98.74	98.01
6	12	0.355 6	0.745 7	95.45	97.09	92.15	94.90
7	12	0.355 6	1.491 4	97.64	95.45	95.45	96.18
8	12	0.355 6	2.237 1	95.45	97.64	91.06	94.72
9	12	0.533 4	0.000 0	94.90	94.90	94.90	94.90
10	12	0.533 4	0.745 7	97.64	96.55	96.55	96.91
11	12	0.533 4	1.491 4	97.09	98.19	93.25	96.18
12	12	0.533 4	2.237 1	97.64	95.45	91.06	94.72
13	48	0.177 8	0.000 0	92.98	92.98	93.80	93.26
14	48	0.177 8	0.745 7	97.50	98.32	98.32	98.05
15	48	0.177 8	1.491 4	96.27	97.09	96.69	96.68
16	48	0.177 8	2.237 1	97.92	96.27	97.09	97.09
17	48	0.355 6	0.000 0	92.15	94.62	93.80	93.53
18	48	0.355 6	0.745 7	98.22	97.50	98.32	98.01
19	48	0.355 6	1.491 4	97.92	97.50	98.74	98.05
20	48	0.355 6	2.237 1	96.27	95.86	98.74	96.96
21	48	0.533 4	0.000 0	93.80	97.09	95.45	95.45
22	48	0.533 4	0.745 7	95.86	97.92	96.69	96.82
23	48	0.533 4	1.491 4	97.92	97.92	96.27	97.37
24	48	0.533 4	2.237 1	97.92	96.27	98.74	97.64

分析表 3 中数据可以得知, 本文提出的滚动轴承故障预测模型对不同工况下滚动轴承的内圈故障、

滚动体故障和外圈故障均能进行有效预测, 内圈故障准确率平均值为 96.43%, 滚动体故障准确率平均值

为 96.72%，外圈故障准确率平均值为 95.96%，总的故障预测准确平均率能达到 96.37%。

3.2 实验对比分析

相关研究中，文献 [5-9] 也分别采用不同的方法对西储大学的滚动轴承数据进行了分析，与文献 [5-9] 所提出的方法相比，采用本文提出的方法得到的滚动轴承故障预测准确率有所提升，具体的准确率对比数据如表 4 所示。

表 4 采用不同方法得到的滚动轴承故障预测准确率
Table 4 Prediction accuracy of rolling bearing fault by using different methods

研究方法	预测准确率 /%
支持向量机 ^[5]	95.33
粒子群优化算法改进的模糊支持向量机 ^[6]	93.75
小波包与 BP 神经网络相结合 ^[7]	92.50
一维卷积神经网络 ^[8]	94.22
二维卷积神经网络 ^[9]	93.04
本文方法	96.37

文献 [5] 将滚动轴承不同故障信号的时间 - 小波能量谱熵作为向量特征，输入支持向量机进行模型训练；文献 [6] 采用小波三层分解对滚动轴承故障信号进行能量特征提取，并输入模糊支持向量机进行模型训练，由于支持向量机借助二次规划来求解支持向量，当求解规模较大时，将耗费大量的内存和运算时间，因此对大规模样本难以完成模型训练。文献 [5] 和文献 [6] 的实验中仅分别采用 11 组和 120 组样本进行训练，训练数据过少，导致模型缺乏泛化性。本文采用 12 780 组样本进行训练，并通过 DS 证据理论对训练结果进行融合，使得本文得到的模型更能适应不同工况下滚动轴承的故障预测。

文献 [7] 采用小波包分解提取滚动轴承各故障信号的特征向量，并输入 BP 神经网络直接进行模型训练，但未对神经网络进行优化设置。文献 [8] 采用一维卷积神经网络对滚动轴承故障进行识别，但全连接层神经元个数的设置较为耗时，且对预测结果影响较大。文献 [9] 将一维滚动轴承振动信号转换成二维灰度图像，并采用二维卷积神经网络对故障进行识别，但是不同卷积层的卷积核个数和大小的设置对于预测结果的影响较大。

由于神经网络的结构和参数设置对模型的收敛速度、泛化性和预测准确率等有较大的影响，故本研究对 BP 神经网络进行了优化设置，并且通过实验比较了不同隐藏层节点数对预测准确率和训练时间的影响。同时采用 DS 证据理论对多个神经网络的输出结果进行了融合，进一步提升了模型的泛化性和故障预测的准确率。

4 结语

本文提出了一种基于 BP 神经网络和 DS 证据理论的滚动轴承故障预测方法，并对西储大学的滚动轴承数据进行了分析。采用小波包分解对基座端、驱动端和风扇端 3 个传感器采集的原始振动数据进行了特征分析，得到的特征向量作为 BP 神经网络的输入。选取最佳网络结构和训练参数后进行神经网络训练，得到基座端、驱动端和风扇端对应的神经网络模型和滚动轴承故障分类结果。使用 DS 证据理论对 3 个神经网络的输出结果进行融合，并输出最终的故障预测结果。实验结果表明，该方法能对不同工况下的滚动轴承故障进行有效预测。

鉴于 BP 神经网络的权重系数、阈值以及隐藏层节点数的设置会影响故障预测的准确率，下一步将采用量子粒子群优化算法对 BP 神经网络的权重系数和阈值进行优化，并自动寻优隐藏层节点数。

参考文献:

- [1] 李舜酩, 郭海东, 李殿荣. 振动信号处理方法综述 [J]. 仪器仪表学报, 2013, 34(8): 1907-1915.
LI Shunming, GUO Haidong, LI Dianrong. Review of Vibration Signal Processing Methods[J]. Chinese Journal of Scientific Instrument, 2013, 34(8): 1907-1915.
- [2] 胡智勇, 胡杰鑫, 谢里阳, 等. 滚动轴承振动信号处理方法综述 [J]. 中国工程机械学报, 2016, 14(6): 525-531.
HU Zhiyong, HU Jiexin, XIE Liyang, et al. Review on Signal Processing for Rolling Bearing Vibrations[J]. Chinese Journal of Construction Machinery, 2016, 14(6): 525-531.
- [3] BOUDIAF A, DJEBALA A, BENDJMA H, et al. A Summary of Vibration Analysis Techniques for Fault Detection and Diagnosis in Bearing[C]//2016 8th International Conference on Modelling, Identification and Control (ICMIC). Algiers: IEEE Press, 2016: 37-42.
- [4] LI C, DE OLIVEIRA J V, CERRADA M, et al. A Systematic Review of Fuzzy Formalisms for Bearing Fault Diagnosis[J]. IEEE Transactions on Fuzzy Systems, 2019, 27(7): 1362-1382.
- [5] 唐贵基, 邓飞跃, 何玉灵, 等. 基于时间 - 小波能量谱熵的滚动轴承故障诊断研究 [J]. 振动与冲击, 2014, 33(7): 68-72, 91.
TANG Guiji, DENG Feiyue, HE Yuling, et al. Rolling Element Bearing Fault Diagnosis Based on Time-Wavelet Energy Spectrum Entropy[J]. Journal of Vibration and Shock, 2014, 33(7): 68-72, 91.
- [6] 林雅慧, 王海瑞, 靖婉婷. 基于改进的 PSO 算法优化

- FSVM的滚动轴承故障诊断[J]. 计算机应用与软件, 2018, 35(11): 94-97, 141.
- LIN Yahui, WANG Hairui, JING Wanting. Fault Diagnosis of Rolling Bearing Based on Improved PSO and FSVM[J]. Computer Applications and Software, 2018, 35(11): 94-97, 141.
- [7] 黄良沛, 吴超威, 王靖. 小波包分析和BP神经网络在滚动轴承故障模式识别中的应用[J]. 电子测量技术, 2016, 39(4): 164-168.
- HUANG Liangpei, WU Chaowei, WANG Jing. Fault Pattern Recognition of Rolling Bearing Using Wavelet Package Analysis and BP Neural Network[J]. Electronic Measurement Technology, 2016, 39(4): 164-168.
- [8] 于景洋, 宁德军, 毛建华. 基于1D卷积神经网络的滚动轴承故障诊断方法[J]. 工业控制计算机, 2019, 32(6): 90-92.
- YU Jingyang, NING Dejun, MAO Jianhua. Rolling Bearing Fault Diagnosis Method Based on 1D Convolutional Neural Network[J]. Industrial Control Computer, 2019, 32(6): 90-92.
- [9] 贺思艳, 任利娟, 田新诚. 基于卷积神经网络的滚动轴承故障诊断[J]. 兵工自动化, 2019, 38(3): 39-41.
- HE Siyan, REN Lijuan, TIAN Xincheng. Rolling Bearing Fault Diagnosis Based on Convolution Neural Network[J]. Ordnance Industry Automation, 2019, 38(3): 39-41.
- [10] 李锋, 陈勇, 王家序, 等. 基于强化学习单元匹配循环神经网络的滚动轴承状态趋势预测[J/OL]. 计算机集成制造系统: 1-14. [2019-11-29]. <http://kns.cnki.net/kcms/detail/11.5946.tp.20190315.0936.022.html>.
- LI Feng, CHEN Yong, WANG Jiaxu, et al. State Trend Prediction of Rolling Bearing Based on Reinforcement Learning Unit Matching Recurrent Neural Network[J/OL]. Computer Integrated Manufacturing Systems: 1-14. [2019-11-29]. <http://kns.cnki.net/kcms/detail/11.5946.tp.20190315.0936.022.html>.
- [11] 曲建岭, 余路, 高峰, 等. 基于移不变字典学习和稀疏编码的滚动轴承故障识别算法[J]. 计算机应用研究, 2019, 36(1): 41-44, 72.
- QU Jianling, YU Lu, GAO Feng, et al. Fault Recognition Algorithm for Rolling Bearings Based on Shift Invariant Dictionary Learning and Sparse Coding[J]. Application Research of Computers, 2019, 36(1): 41-44, 72.
- [12] WANG J, QIAO W, QU L Y. Wind Turbine Bearing Fault Diagnosis Based on Sparse Representation of Condition Monitoring Signals[J]. IEEE Transactions on Industry Applications, 2019, 55(2): 1844-1852.
- [13] HOU Z R. Rolling Bearing Fault Diagnosis Based on Wavelet Packet and Improved BP Neural Network for Wind Turbines[J]. Applied Mechanics and Materials, 2013, 347/348/349/350: 117-120.
- [14] HUI K H, LIM M H, LEONG M S, et al. Dempster-Shafer Evidence Theory for Multi-Bearing Faults Diagnosis[J]. Engineering Applications of Artificial Intelligence, 2017, 57: 160-170.
- [15] 祁友杰, 王琦. 多源数据融合算法综述[J]. 航天电子对抗, 2017, 33(6): 37-41.
- QI Youjie, WANG Qi. Review of Multi-Source Data Fusion Algorithm[J]. Aerospace Electronic Warfare, 2017, 33(6): 37-41.
- [16] Case Western Reserve University Bearing Data Center. Fault Bearing Test Data[EB/OL]. [2019-05-20]. <https://csegroups.case.edu/bearingdatacenter/home>.

(责任编辑: 廖友媛)