

DOI:10.3969/j.issn.1003-5060.2025.04.003

基于小波包分解和神经网络集成群的 滚动轴承故障诊断

柴立平, 孟壮壮, 石海峡, 李强

(合肥工业大学 机械工程学院, 安徽 合肥 230009)

摘要:文章提出一种将多个神经网络相结合的神经网络集成群算法进行滚动轴承故障诊断。首先对原始振动信号进行小波包变换,分别采用小波包能量和小波包样本熵作为特征向量;其次采用多个粒子群优化反向传播(particle swarm optimization-back propagation, PSO-BP)神经网络分别对轴承进行故障诊断,比较分析小波包能量和小波包样本熵作为特征向量的适配程度;再以多个神经网络作为神经网络集成群的基础子网络,通过统计耦合、输出耦合和统计输出耦合形成神经网络集成群的二级网络;最后通过最终统计耦合输出神经网络集成群的分类结果。研究表明,该方法可获得理想的滚动轴承故障诊断准确率,在负载变化时具有良好的泛化性能。

关键词:滚动轴承;故障诊断;小波包变换;粒子群优化反向传播神经网络;神经网络集成群

中图分类号:TH17 **文献标志码:**A **文章编号:**1003-5060(2025)04-0447-08

Rolling bearing fault diagnosis based on wavelet packet decomposition and neural network integrated swarm

CHAI Liping, MENG Zhuangzhuang, SHI Haixia, LI Qiang

(School of Mechanical Engineering, Hefei University of Technology, Hefei 230009, China)

Abstract: A neural network integrated swarm algorithm that combines multiple neural networks is proposed for rolling bearing fault diagnosis. Firstly, wavelet packet transform was performed on the original vibration signal, and wavelet packet energy(WPE) and wavelet packet sample entropy(WPSE) were used as feature vectors' respectively. Secondly, multiple particle swarm optimization-back propagation(PSO-BP) neural network pairs were used to diagnose the bearing faults separately and compare the adaptability of WPE and WPSE as feature vectors. Then, by using these neural networks as the basic sub-networks of the neural network integrated swarm, the secondary networks of the neural network integrated swarm were formed through statistical coupling, output coupling, and statistical and output coupling. Finally, the classification results of the neural network integrated swarm were output through the final statistical coupling. The results show that the method can obtain the desired accuracy of rolling bearing fault diagnosis and has good generalization performance when the load changes.

Key words: rolling bearing; fault diagnosis; wavelet packet transform; particle swarm optimization-back propagation(PSO-BP) neural network; neural network integrated swarm

滚动轴承是现代机器中应用最广泛的通用零件之一,可将转轴与轴座之间的滑动摩擦转变为

滚动摩擦,对维持设备的平稳运行起到重要作用^[1]。轴承的工作环境一般较为恶劣,是最易损

收稿日期:2023-03-23;修回日期:2023-04-03

基金项目:安徽省科技重大专项资助项目(202203a05020026);安徽省高校协同创新资助项目(GXXT-2019-004)

作者简介:柴立平(1969—),男,安徽合肥人,合肥工业大学教授,硕士生导师;

李强(1964—),男,安徽蚌埠人,合肥工业大学教授,硕士生导师。

坏的机械元件之一。据统计,70%的机械故障可以通过振动形式表现出来,其中30%是由轴承故障引起的^[2]。因此,振动信号分析是诊断轴承局部缺陷的最佳方法之一^[3]。

虽然机械振动信号极其复杂,但每种类型的故障都有其固有特征。这种固有特性使得不同的故障信号与正常信号之间可能存在一些本质差异。故障诊断的目的是找出这种差异,对于基于振动信号的故障诊断,通常分为特征提取和模式识别等两步骤^[4]。故障特征是表征机械系统运行状态的重要参数,可通过一定的处理方法从振动信号中提取。故障特征提取是机械故障诊断的首要任务,也是模式识别阶段的基础,对故障诊断的准确性有重要影响^[5]。

模式识别是识别机械故障类型的过程,即建立模式识别分类器的过程。故障特征提取一般包括时域特征提取、频域特征提取和时频域特征提取。常用的模式识别分类器包括支持向量机、反向传播(back propagation, BP)神经网络、贝叶斯分类器、集成学习、强化学习等^[6]。文献[7]先采用统计分析和快速傅里叶变换提取时域和频域特征,再利用变分模态分解对振动信号进行分解并提取时频域特征,以支持向量机分类模型识别不同的轴承工况;文献[8]使用小波包分解提取滚动轴承振动信号中的能量值,提出一种基于布谷鸟搜索算法优化的BP神经网络模型用于滚动轴承故障诊断;文献[9]通过局部均值分解和多尺度熵提取特征向量,采用BP神经网络对滚动轴承进行故障诊断;文献[10]采用经验模态分解能量熵作为特征向量,与人工神经网络结合用于检测和识别轴承故障严重程度。

以上算法虽然都用到了不同的模式识别分类器,但都是单一的识别分类器,即使对其进行优化也很难全面处理从原始故障信号中提取的特征,特别是原始信号中含有大量的噪音和干扰信号时。为了解决这些问题,本文提出一种神经网络集成群算法对滚动轴承进行故障诊断,即采用多个BP神经网络作为模式识别分类器,并通过一定的方法将其结合在一起形成一个神经网络集成群,充分全面处理从原始故障信号中提取到的特征,提高故障识别准确率。

本文采用小波包能量(wavelet packet energy, WPE)和小波包样本熵(wavelet packet sample entropy, WPSE)作为故障特征,以基于粒子群优化反向传播(particle swarm optimization-

back propagation, PSO-BP)神经网络作为模式识别分类器,研究影响诊断正确率的因素,讨论故障严重程度和负载的影响,探讨更适合滚动轴承故障诊断的故障特征,比较神经网络集成群算法相对于单个神经网络对故障的诊断准确率,并给出一种提高诊断准确率的方法。

1 基本理论

1.1 小波包变换及特征提取

小波包分解可将原始振动信号分解为位于不同频段内的子信号,而滚动轴承在不同运行状态下的振动信号与其子信号具有本质的差异,而特征提取就是找出此本质差异的过程。

1.1.1 小波包分解

小波包分解是小波分解的改进,小波分解可以表现信号在时频域的局部特征,但只可以在下一步中分解信号的低频部分,而不能处理高频部分;小波包分解不仅可以对信号中的低频成分进行再分解,还可以对信号中的高频成分进行再分解,低频处获得较高的频域分辨率,而在高频部分可获得较高的时域分辨率,与小波分解相比其对原始信号的频带划分更为详细^[11-12]。以原始信号3层小波包分解为例,分解示意图如图1所示。图1中:S为原始信号;L为高频成分;H为低频成分。一个信号可分解为低频和高频2个子带,且任意子带都可再分解为低频和高频2个子子带。对于 n 层小波包分解,可以将原始信号分解为 2^n 个位于不同频带的子信号,原始信号也可以由此 2^n 个子信号重构。




图1 小波包分解示意图

1.1.2 小波包能量

小波包能量是信号分析的一个重要参数,反映了信号的频率特性变化。原始信号的能量等于小波包分解后各个子频带的之和,即

$$E = \int_{-\infty}^{+\infty} |f(x)|^2 dx = \sum_{i=1}^{2^j} E_i \quad (1)$$

其中: $f(x)$ 为原始信号; j 为小波包分解层数;

E_i 为第 i 频带能量。 E_i 计算公式为:

$$E_i = \sum_{k=1}^n x_{i,k}^2 \quad (2)$$

其中, $x_{i,k}$ 为第 i 个频段的第 k 个投影系数。

1.1.3 小波包样本熵

样本熵是一种时间序列复杂性的度量方法。通过小波包分解得到的不同频带的系数序列,可计算出各个频带的样本熵,即小波包样本熵。样本熵的计算方法^[13]如下。

1) 将某频段系数序列 $\{x(n)\} = \{x(1), x(2), \dots, x(N)\}$ 组成 m 维向量,即

$$\mathbf{X}_m = (x(i), x(i+1), \dots, x(i+m-1)) \quad (3)$$

其中, $1 \leq i \leq N-m+1$ 。

2) 定义向量 $\mathbf{X}_m(i)$ 与 $\mathbf{X}_m(j)$ 之间的距离为 X_m^j , 其计算公式为:

$$X_m^j = \max[|x(i+k) - x(j+k)|]_{k=0,1,\dots,m-1} \quad (4)$$

3) 给定阈值 r , 对任一个 i , 统计 $X_m^j < r$ 的个数, 记作 B_i , 定义 $B_i^m(r)$ 为:

$$B_i^m(r) = \frac{B_i}{N-m-1} \quad (5)$$

4) 定义 $B^m(r)$ 计算公式为:

$$B^m(r) = \frac{1}{N-m} \sum_{i=1}^{N-m} B_i^m(r) \quad (6)$$

5) 采用相同的方法将序列 $\{x(n)\} = \{x(1), x(2), \dots, x(N)\}$ 扩展到 $m+1$, 可得:

$$A^{m+1}(r) = \frac{1}{N-(m+1)} \sum_{i=1}^{N-(m+1)} A_i^{m+1}(r) \quad (7)$$

6) 计算可得到某频段的样本熵, 即

$$S_n(m, r) = \lim_{N \rightarrow \infty} \left\{ -\ln \left[\frac{A^{m+1}(r)}{B^m(r)} \right] \right\} \quad (8)$$

样本熵值受 m 和 r 取值的影响, 常取 $m=2$, r 范围为 $(0.10 \sim 0.25) \text{std}$ (std 为信号的标准差)。

1.2 PSO-BP 神经网络

BP 神经网络具有良好的非线性映射能力、自学习和自适应能力、泛化能力和容错能力, 使其在故障诊断领域得到广泛的应用。然而, 传统的 BP 神经网络收敛速度慢, 且很容易陷入局部最优值^[14-15]。为克服传统 BP 神经网络的缺点, 本文采用粒子群优化算法 (particle swarm optimization, PSO)^[16] 对其进行优化处理。PSO 是由 Eberhart 和 Kennedy 共同提出的用于解决最优化的搜索算法, 也是最为经典的智能算法之一。

PSO-BP 神经网络包括 BP 网络结构确定、粒子群算法优化和 BP 网络预测 3 个部分。粒子群

算法灵感来自于对鸟群捕食的行为研究, 该算法最初是受到飞鸟集群活动的规律性启发, 进而利用群体智能建立的一个简化模型^[17]。PSO-BP 神经网络构建过程如下。

1) 确定 BP 神经网络结构。

2) 创建大量粒子, 若 BP 神经网络的权值和偏置共 D 个, 则 D 维向量 $\mathbf{X}_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ 代表第 i 个粒子在 D 维空间中的位置, 即 BP 神经网络的参数一个解, D 维向量 $\mathbf{V}_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ 代表第 i 个粒子的速度, D 维向量 $\mathbf{P}_i = (p_{i1}, p_{i2}, \dots, p_{iD})$ 代表第 i 个粒子的最佳位置, D 维向量 $\mathbf{P} = (p_1, p_2, \dots, p_D)$ 代表整个粒子群的最佳位置; 并初始化粒子群位置和速度。

3) 计算每个粒子的适应度。

4) 更新每个粒子以及整个粒子群的历史最佳适应度, 并记录其位置。

5) 更新每个粒子的速度和位置, 更新方法计算公式为:

$$\begin{cases} v_{id}(n) = \epsilon v_{id}(n-1) + c_1 r_1 [p_{id}(n) - x_{id}(n)] + c_2 r_2 [p_{id}(n) - x_{id}(n)], \\ x_{id}(n) = x_{id}(n-1) + v_{id}(n-1)t \end{cases} \quad (9)$$

其中: n 为当前迭代次数; d 为对应向量的第 d 个维度, 取值为 $1, 2, \dots, D$; ϵ 为惯性权重; c_1, c_2 分别为自我学习因子和社会学习因子; r_1, r_2 为 $(0, 1)$ 之间的随机数; 时间 t 取 1。

6) 从步骤 3) 开始迭代, 直到达到设定迭代次数, 结束迭代。

7) 得到整个粒子群历史最佳适应度所在位置, 即完成对 BP 神经网络权值、偏置的优化。

在粒子探索前期, 若要能够探索到整个空间, 则需要粒子速度大一些, 每个粒子以自身最佳位置为学习的重点; 在粒子探索后期, 若要能够探索到精确的位置, 则需要粒子速度小一些, 每个粒子以整个粒子群最佳位置为学习的重点。则惯性权重、自我学习因子和社会学习因子随迭代步数的变化为:

$$\begin{cases} \epsilon = \epsilon_{\max} - n(\epsilon_{\max} - \epsilon_{\min})/N, \\ c_1 = c_{1\max} - n(c_{1\max} - c_{1\min})/N, \\ c_2 = c_{2\min} + n(c_{2\max} - c_{2\min})/N \end{cases} \quad (10)$$

其中: n 为当前迭代次数; N 为最大迭代次数; $\epsilon_{\max}, \epsilon_{\min}$ 分别为 ϵ 的最大值和最小值; $c_{1\max}, c_{1\min}$ 分别为 c_1 的最大值和最小值; $c_{2\max}, c_{2\min}$ 分别为 c_2 的最大值和最小值。

2 结果分析和讨论

本文采用的滚动轴承数据集来自于美国凯斯

西储大学电气工程实验室。实验台如图 2 所示,左侧为用于产生驱动力的 1.4 kW 电机,右侧为用于产生负载的测力计,通过扭矩传感器连接两者。电机轴承为 SKF 6205,使用电火花技术加工故障,分别在滚道、滚动体和外滚道负载区处加工直径为 0.18、0.36、0.54 mm 的单点故障。记录 0、0.7、1.4、2.1 kW 等 4 种负载工况下的振动数据。本文选取采样频率为 12 kHz 的驱动端轴承故障时的振动信号。




图 2 滚动轴承实验台

本文以轴承旋转整数圈时传感器所采集的信号为 1 组样本,轴承旋转 1 圈时采集的数据大小 n 与传感器采样频率和转速关系为:

$$n = 60f/v \quad (11)$$

其中: f 为采样频率; v 为转速。

通过式(11)可得轴承每旋转一周传感器大约采集 400 个样本点。本文神经网络训练样本取自

负载为 0 的振动信号,训练样本包括 1 200 个样本点。实验对滚动轴承数据样本进行 4 小波包分解,计算得到 16 个频带的能量值和样本熵值。由不同频带的能量值或样本熵值组成 16 维特征向量。

本文最初训练和测试样本来自于零负载的数据,并将 0.18、0.36、0.54 mm 等不同尺寸的同类故障作为同类型,故本文研究的是一个滚动轴承四分类问题,即轴承的正常、内圈故障、滚子故障和外圈故障等 4 种状态。将每类故障的轴承故障样本按照 7:3 随机分配到训练样本集和测试样本集。

利用训练样本训练 PSO-BP 神经网络。为避免单个神经网络的偶然性,采用分别具有 1、2、3 层隐含层的 3 个 BP 神经网络,分别将其命名为神经网络 1、神经网络 2 和神经网络 3。

2.1 轴承故障诊断准确率对比

神经网络 1、神经网络 2 和神经网络 3 的训练样本均来自于零负载的数据,为研究基于 WPE 与 WPSE 的轴承诊断在不同负载下诊断准确率的泛化能力,本文对 0.7、1.4、2.1 kW 负载的样本数据也进行故障预测。

轴承状态分别为内圈故障、滚子故障、外圈故障诊断准确率及三者准确率的平均值,分别如图 3~图 6 所示(滚动轴承正常状态在负载为 0、0.7、1.4、2.1 kW 时的诊断准确率均为 100%,故在图中不在单独展示)。

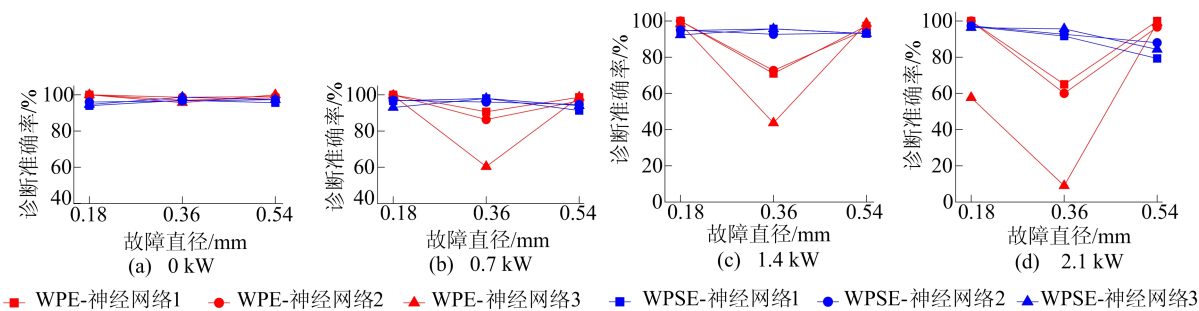


图 3 滚动轴承内圈故障诊断准确率

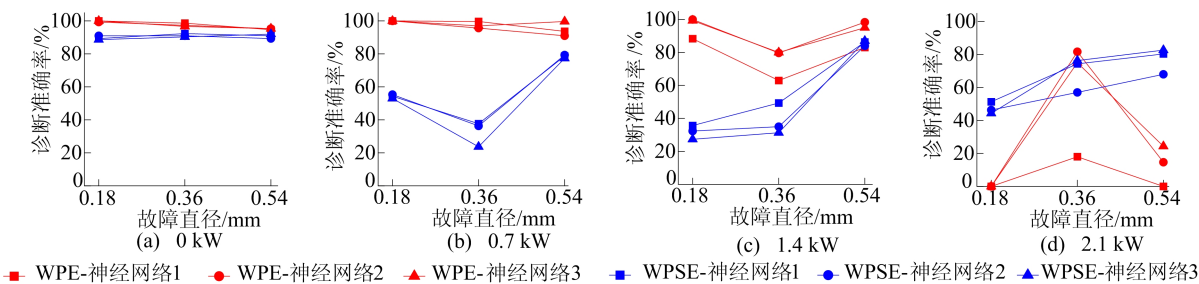


图 4 滚动轴承滚子故障诊断准确率

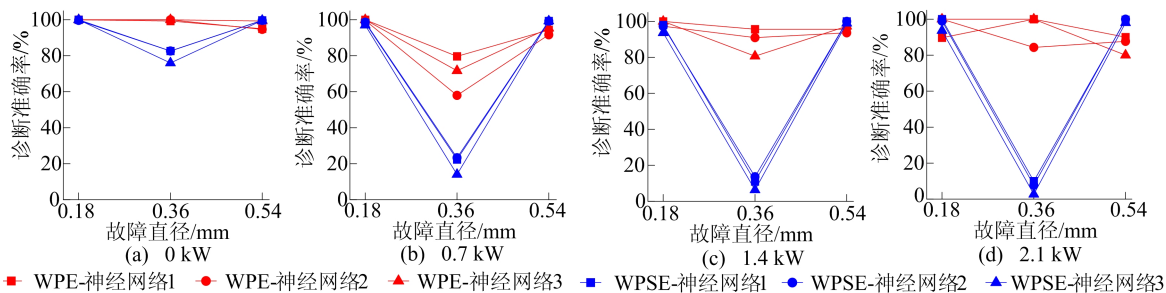


图5 滚动轴承外圈故障诊断准确率

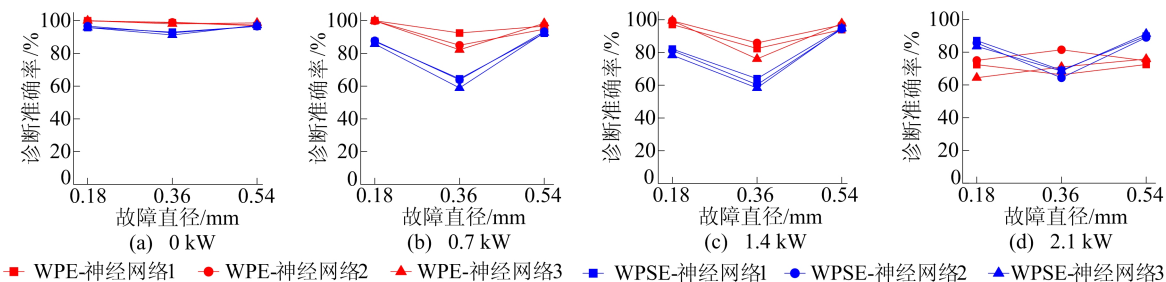


图6 滚动轴承3种故障、滚子故障、外圈故障的平均诊断准确率

从图3可以看出,在任一负载下,对于轴承内圈故障,在故障直径为0.18、0.54 mm时基于WPE的故障诊断略优于基于WPSE的,但在故障直径为0.36 mm时基于WPSE的故障诊断明显优于基于WPE的。从图4可以看出,对于轴承滚子故障,当不超过电机额定负载1.4 kW时,基于WPE的故障诊断优于基于WPSE的,但当负载达到2.1 kW时,情况相反。

从图5可以看出,对于轴承外圈故障,在故障直径为0.18、0.54 mm时基于WPE和基于WPSE的故障诊断准确率相差不大,但对于0.36 mm的故障直径,基于WPE的故障诊断准确率远远高于基于WPSE的,且随着负载的增大更为明显。

从图6可以看出:对于轴承故障总体而言,当电机额定负载不超过1.4 kW时基于WPE的故障诊断优于基于WPSE,但当负载达到2.1 kW时,二者各有优劣;基于WPE的故障诊断通常在故障直径为0.18 mm时有最高的诊断准确率,而基于WPSE的故障诊断通常在故障直径为0.54 mm时有最高的诊断准确率。

由诊断结果可知,WPE特征更适合于负载较低时滚动轴承的早期故障诊断,WPSE特征对负载较高时滚动轴承的严重故障诊断更有效。总体而言,在电机额定负载未超过1.4 kW时,基于WPE在实际诊断中比基于WPSE有更高的准确性,更适合工程应用。

2.2 神经网络群

从2.1节可知,基于WPE的神经网络1、神经网络2和神经网络3输出结果对不同故障尺寸和不同负载各有优缺点,例如神经网络1对负载为0.7 kW、故障直径为0.36 mm的诊断性能相对另外2个神经网络更好,神经网络3对故障直径为0.54 mm的诊断相对另外2个神经网络有更好的诊断性能。为了使3个神经网络的诊断性能取长补短,现提出3种方式将三者耦合在一起。

第1种是取神经网络1、神经网络2和神经网络3的最多的诊断结果作为诊断结果,若3个神经网络诊断结果各不相同,从图6可以看出,对滚动轴承故障诊断总体而言,神经网络2的诊断准确率要略优于神经网络1和神经网络3,故取神经网络2的诊断结果,将其命名为统计耦合。

第2种是将神经网络1、神经网络2和神经网络3的输出向量组成一个新的向量,本文为4分类问题,故神经网络1、神经网络2和神经网络3的输出为4维向量,可将其组合成一个12维向量,并将其作为另一个新的神经网络的输入特征向量,该神经网络也采用PSO-BP神经网络,对其训练后以该神经网络输出滚动轴承故障诊断结果,将其命名为输出耦合。

第3种是将前2种结合在一起,即若神经网络1、神经网络2和神经网络3诊断结果相同,则取此诊断结果,若三者诊断结果不同则与输出耦合相同,将其命名为统计输出耦合。

最后将 3 种耦合方式诊断结果结合在一起, 取 3 种耦合最多的诊断结果作为最终诊断结果, 将其命名为最终统计耦合, 具体诊断流程如图 7 所示。

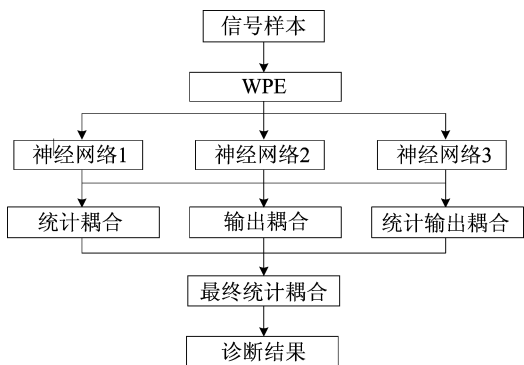


图 7 神经网络集成群诊断流程

为比较各种耦合方式与原神经网络的诊断性能, 选取不同故障直径和不同负载下各种原神经网络和耦合的诊断结果如图 8 所示, 图 8 中轴承状态包括内圈故障、滚子故障和外圈故障, 且三者样本数相同。

从图 8 可以看出, 统计耦合要略优于输出耦合和统计输出耦合, 故当 3 种耦合诊断结果各不相同, 则最终统计耦合取统计耦合的诊断结果。当故障直径为 0.18、0.36 mm 时, 最终统计耦合的诊断准确性要明显高于其他方式。当故障直径为 0.54 mm 时, 最终统计耦合的诊断准确性略逊于输出耦合, 但仍要高于其他方式。总体而言, 最终统计耦合的诊断性能最好。可以看出, 对较低性能的神经网络进行集成以形成神经网络群, 可大幅度提高神经网络的诊断精度。

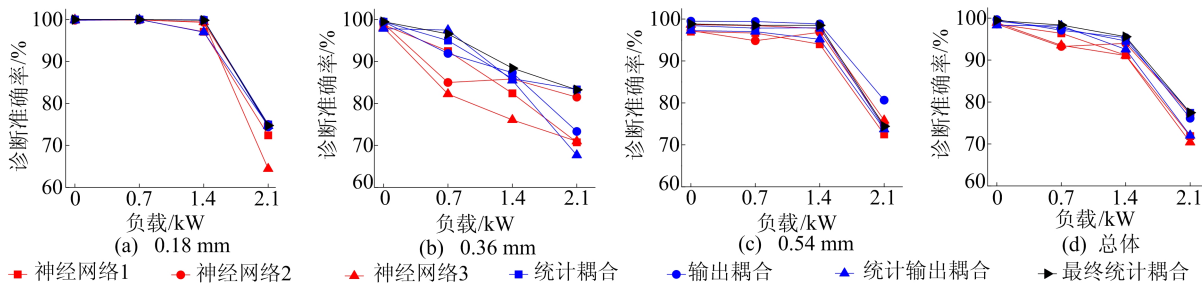


图 8 各种神经网络和耦合方式的诊断精度

2.3 多层诊断

为避免偶然性, 提高故障诊断准确性, 通常可增加单个样本长度或取多个样本的诊断结果的最大值为最终诊断结果。为充分利用样本信号中的信息, 在上述方法的基础上, 本文提出一种取多层样本的诊断结果的平均值作为最终的诊断结果,

将其命名为多层诊断。以 3 层为例, 具体模型如图 9 所示。通常方法是取顶层小样本 1.1 的诊断结果或底层小样本 1.4 至小样本 1.7 的诊断结果的最大值作为大样本 1 的诊断结果, 这里分别将其命名为顶层诊断和底层诊断。本文提出的多层诊断诊断流程如下描述。




图 9 诊断样本重组模型

由图 9 可知, 一个大样本的第 x 层有 2^{x-1} 个小样本。对于一个 n 分类问题, 多层诊断首先需要设一个全 0 的 n 维行向量 $\mathbf{a} = [0 \ 0 \ \dots \ 0]$; 若大样本的第 x 层的某个小样本被判定为第 i 类, 则

$$a_i = a_i + \frac{1}{2^{x-1}} \quad (12)$$

将一个大样本的全部小样本分类后可得到更新后的向量 \mathbf{a} , 则大样本属于的第 j 类为:

$$j = \max \text{Where}(a) \quad (13)$$

其中, $\max \text{Where}(\cdot)$ 表示向量中的最大数所在位置。

为比较3种诊断方式的优劣性,本文选取不同的大样本长度和分层数对其进行故障诊断,已知旋转轴承1圈传感器采集400个样本点,为保证诊断小样本长度为轴承整圈,底层小样本长度至少有400个样本点或其整数倍,不同诊断方式诊断准确率见表1所列。

由表1可知,顶层或底层诊断准确率高,多层诊断准确率主要集中在高负载区,此时诊断准

准确率普遍较低。

比较表1的1、2、4组数据可知,滚动轴承故障诊断准确率随着大样本长度增长而增高;比较4、5、6组数据可发现,当大样本长度足够长时,并不是层数越多准确率越高,而是需要选择合适的层数才可以获得理想的诊断准确率,这是由于随着层数的增加,底层小样本的长度变短,底层小样本准确率降低,进而影响大样本的准确率。

从诊断结果可以看出,本文提出的多层诊断方式优于传统的顶层和底层诊断方式,尤其在诊断准确率较高时更为明显。

表1 不同诊断方式的准确率

组数	大样本长度	层数	诊断方式	不同负载下诊断准确率/%			
				0 kW	0.7 kW	1.4 kW	2.1 kW
1	1 600	3	顶层	99.13	97.40	94.97	71.88
			底层	96.53	96.35	88.19	64.41
			多层	99.13	98.09	94.62	71.53
2	3 200	3	顶层	99.65	98.96	96.88	73.26
			底层	99.31	98.26	93.75	70.49
			多层	99.65	99.31	96.88	73.26
3	3 200	4	顶层	99.65	98.96	96.53	73.26
			底层	99.65	99.31	93.06	68.75
			多层	100.00	99.31	96.88	73.26
4	6 400	3	顶层	100.00	100.00	97.92	74.31
			底层	100.00	98.61	97.92	75.00
			多层	100.00	100.00	98.61	74.31
5	6 400	4	顶层	100.00	100.00	97.92	74.31
			底层	100.00	98.61	95.14	72.92
			多层	100.00	100.00	100.00	75.00
6	6 400	5	顶层	100.00	100.00	97.92	74.31
			底层	100.00	99.31	96.53	68.75
			多层	100.00	100.00	100.00	73.61

3 结 论

本文提出了一种基于小波包分解和神经网络集成群的轴承故障诊断算法,研究WPE特征和WPSE特征对滚动轴承故障诊断的影响以及神经网络集成群对滚动轴承故障诊断准确性的作用,分析不同诊断方式对滚动轴承故障诊断准确率的影响。主要结论如下:

1) WPE特征更适合于负载较低时滚动轴承的早期故障诊断,WPSE特征对负载较高时滚动轴承的严重故障诊断更有效;总体而言,基于WPE在实际诊断中比基于WPSE有更高的准确性,更适合工程应用。

2) 相对于单个神经网络算法,神经网络集成

群算法的故障分类准确性得到明显提高。

3) 与传统底层诊断或顶层诊断相比,本文提出的多层诊断可以更加有效地发掘信号中包含的信息,进一步提高滚动轴承故障诊断准确率。

4) 实验结果表明,本文方法具有良好的泛化性能,即使负载发生变化,在未超过电机的额定功率时仍然保持理想的故障识别率。

[参 考 文 献]

- [1] 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.
- [2] 张兰芳,张朝龙,纪娟娟.基于核主元分析和极端学习机的轴承故障诊断方法[J].电子测量与仪器学报,2018,32(2):23-29.

- [3] MING Y, CHEN J, DONG G G. Weak fault feature extraction of rolling bearing based on cyclic wiener filter and envelope spectrum[J]. *Mechanical Systems and Signal Processing*, 2011, 25(5): 1773-1785.
- [4] LI Q, JI X, LIANG S Y. Incipient fault feature extraction for rotating machinery based on improved ar-minimum entropy deconvolution combined with variational mode decomposition approach[J]. *Entropy*, 2017, 19(7): 317-342.
- [5] GUO T, DENG Z M. An improved EMD method based on the multi-objective optimization and its application to fault feature extraction of rolling bearing[J]. *Applied Acoustics*, 2017, 127: 46-62.
- [6] JIN Z, HE D, CHEN Y, et al. Research on fault diagnosis method of train rolling bearing based on variational modal decomposition and bat algorithm-support vector machine[J]. *Journal of Physics(Conference Series)*, 2021, 1820(1): 012170.
- [7] YAN, X A, JIA M P. A novel optimized svm classification algorithm with multi-domain feature and its application to fault diagnosis of rolling bearing [J]. *Neurocomputing*, 2018, 313: 47-64.
- [8] XIAO M H, LIAO Y B, BARTOS P, et al. Fault diagnosis of rolling bearing based on back propagation neural network optimized by cuckoo search algorithm[J]. *Multimedia Tools and Applications*, 2021, 81(2): 1567-1587.
- [9] LIU H H, HAN M H. A fault diagnosis method based on local mean decomposition and multi-scale entropy for roller bearings[J]. *Mechanism and Machine Theory*, 2014, 75: 67-78.
- [10] ALI J B, FNAIECH N, SAIDI L, et al. Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals[J]. *Applied Acoustics*, 2015, 89: 16-27.
- [11] WU Y P, WU W B. Analysis of wavelet decomposition properties of wind turbine signal[J]. *Science Direct*, 2021, 7(7): 873-879.
- [12] QIU X H, YE Z W. Fault diagnosis of analog circuits based on wavelet packet energy entropy and DBN[J]. *IOP Conference Series (Earth and Environmental Science)*, 2021, 632(4): 042018.
- [13] 向北平, 周建, 倪磊, 等. 基于样本熵的改进小波包阈值去噪算法[J]. *振动、测试与诊断*, 2019, 39(2): 410-415.
- [14] SHEN C Q, QI Y M, WANG J, et al. An automatic and robust features learning method for rotating machinery fault diagnosis based on contractive[J]. *Engineering Applications of Artificial Intelligence*, 2018, 76: 170-184.
- [15] QIANG W A, YU W A, YW A, et al. Ablation state assessment of SF₆ circuit breaker contacts based on BP neural network and mean impact value[J]. *Science Direct*, 2022, 8(5): 874-883.
- [16] LUO Q Y, LI J X, ZHANG H. Drag coefficient modeling of heterogeneous connected platooning vehicles via BP neural network and PSO algorithm[J]. *Neurocomputing*, 2022, 487: 117-127.
- [17] ZHOU G B, ZHOU Y C. Analysis on mass flow rate of R22 and R407C through coiled adiabatic capillary tubes with GA and PSO optimized BP networks[J]. *Journal of Mechanical Science and Technology*, 2020, 34(8): 3445-3455.

(责任编辑 吴亮)

(上接第 446 页)

- [18] NIKAS K S, NIKOLOPOULOS N, NIKOLOPOULOS A. Numerical study of a naturally cross-ventilated building [J]. *Energy and Buildings*, 2010, 42: 422-434.
- [19] CHU C R, CHIU Y H, TSAI Y T, et al. Wind-driven natural ventilation for buildings with two openings on the same external wall [J]. *Energy and Buildings*, 2015, 108: 365-372.
- [20] FAN S, WYKES M S D, LIN W E, et al. A full-scale field study for evaluation of simple analytical models of cross ventilation and single-sided ventilation [J]. *Building and Environment*, 2021, 187: 107386.
- [21] WU M, ZHANG G, AN Z, et al. Modelling of hazardous chemical gas building ingress and consequence analysis during a leak accident[J]. *Indoor and Built Environment*, 2023, 32(4): 783-796.
- [22] LARSEN T S, HEISELBERG P. Single-sided natural ventilation driven by wind pressure and temperature difference [J]. *Energy and Buildings*, 2008, 40(6): 1031-1040.
- [23] BETTS P L, BOKHARI I H. Experiments on turbulent natural convection in an enclosed tall cavity[J]. *International Journal of Heat and Fluid Flow*, 2000, 21(6): 675-683.
- [24] 吴启光. 关于正交试验法的优良性[J]. *应用数学学报*, 1978(4): 283-299.
- [25] 施富清, 史如琴, 肖锋, 等. 正交试验法与模拟计算[J]. *合肥工业大学学报(自然科学版)*, 2001, 24(增刊 1): 777-781.

(责任编辑 吴亮)