

DOI:10.3969/j.issn.1001-4551.2022.03.009

轴承故障的全视角特征提取与模式诊断方法*

庄 燕

(九州职业技术学院,江苏 徐州 221116)

摘要:为了提高轴承故障诊断的准确率,提出了一种轴承故障的全视角特征提取方法和专家森林算法的模式诊断方法。在故障特征提取方面,首先从时域、频域、时频域选择参数,以此来作为初始故障特征库,而后使用 KPCA 提取了基础故障库的全局结构特征,使用 t-SNE 算法提取了基础故障库的局部结构特征,从而保留了对故障模式相对敏感的全视角特征参数;在故障模式识别方面,为决策树赋予了专家属性和专家权值,得到了专家树的概念,基于专家树思想提出了专家森林算法,解决了随机森林算法无差别对待决策树的问题;最后采用实验的方式,对轴承故障全视角特征提取方法和基于专家森林算法的模式诊断方法进行了验证。研究表明:由 KPCA + t-SNE 结合提取的全视角故障特征优于单独提取的全局结构特征与局部结构特征;随机森林算法的诊断准确率均值为 96.14%,专家森林算法的故障诊断准确率均值为 99.48%,比随机森林算法提高了 3.47%,验证了所提故障诊断方法的优越性。

关键词:轴承故障诊断;全局结构特征;局部结构特征;初始特征库;专家森林算法

中图分类号:TH133.3;TH17

文献标识码:A

文章编号:1001-4551(2022)03-0344-06

Whole view feature extraction and mode diagnosis method for bearing faults

ZHUANG Yan

(Jiuzhou Polytechnic, Xuzhou 221116, China)

Abstract: In order to improve the accuracy of bearing fault diagnosis, the full view feature extraction method of bearing fault and the pattern diagnosis method of expert forest algorithm were proposed. Firstly, in terms of fault feature extraction, parameters from time domain, frequency domain and time-frequency domain were selected as the initial fault feature library. Then the global structural features of the basic fault library were extracted using KPCA, and the local structural features of the basic fault library were extracted using t-SNE algorithm, so as to retain the full view feature parameters that were relatively sensitive to fault modes. In the aspect of fault pattern recognition, expert attributes and expert weights were given to the decision tree, and the concept of expert tree was obtained. Based on the idea of expert tree, an expert forest algorithm was proposed, which solves the problem that the random forest algorithm treats the decision tree indiscriminately. Finally, experiments were used to verify the full-view feature extraction method of bearing faults and the mode diagnosis method based on the expert forest algorithm. The experimental results show that the full view fault features extracted by KPCA + t-SNE are better than the global and local structure features extracted separately; the average diagnosis accuracy of random forest algorithm is 96.14%, and the average fault diagnosis accuracy of expert forest algorithm is 99.48%, which is 3.47% higher than that of random forest algorithm, and verifies the superiority of the proposed fault diagnosis method.

Key words: bearing fault diagnosis; global structural features; local structural features; initial feature library; expert forest algorithm

0 引 言

滚动轴承是旋转设备中极其重要的零部件,常被称为“工业的关节”。轴承一般在高温、重载、变载荷等极端环境中长时间工作,因此容易发生裂纹、腐蚀失

效、塑性变形等多种形式的故障。轴承故障会使机械设备或生产线停产,严重时造成设备损毁或威胁人身安全^[1]。因此,研究滚动轴承的故障诊断技术具有重要的经济意义和安全意义。

对滚动轴承故障进行诊断主要流程包括 3 个重要

收稿日期:2021-09-29

基金项目:苏州市教育科学“十三五”规划项目(192012409)

作者简介:庄燕(1981-),女,江苏铜山人,讲师,主要从事数控技术、机械制造、模具设计制造等方面的研究。E-mail:song987520@126.com

方面,即信号采集、特征提取和模式诊断。3个流程具体为:(1)信号采集是依据诊断对象结构特征,选择传感器和信号类型,包括声信号、温度信号、振动信号等。(2)特征提取是对采样信号进行处理和变换,得到能够表征故障模式的特征参数,包括时域参数、频域参数、时频域参数^[2,3]、图形参数特征等。(3)故障模式诊断主要有2种,即基于模型驱动和基于数据驱动的模式。其中,基于模型的诊断技术需要建立轴承动力学模型,而精确模型和参数一般难以获得,因此基于模型诊断方法使用较少。基于数据驱动的诊断方法依据大量历史数据进行故障诊断,包括神经网络、支持向量机^[4]、深度神经网络^[5]等。

范春阳等人^[6]采用希尔伯特边际谱的11个统计参数构造了轴承故障的初始特征,而后对其进行了降维,最终使用随机森林算法对轴承进行了故障模式识别;该方法虽然能有效地提取轴承故障特征,但是随机森林算法存在无差别对待随机树的问题。孙岩等人^[7]使用多尺度卷积核 Inception 结构和空间注意力机制替代神经网络的卷积层,从而提取了不同尺度、重点突出的轴承故障特征参数,同时基于改进胶囊网络实现了对轴承的故障诊断;虽然该方法在噪声环境下仍能取得较好诊断结果,但是胶囊网络参数的整定较为困难,且一般要依赖人工经验。王金东等人^[8]使用复合多尺度模糊熵提取了轴承的间隙故障特征,并使用支持向量机对其进行了故障识别;虽然该方法有效提取了轴承的故障时频域特征,但是忽视了其他域的敏感特征,因此其故障诊断的准确率有限。

针对特征参数敏感度问题和随机森林无差别对待随机树的问题,笔者从故障特征提取和故障模式识别两个角度对其进行研究,即在故障特征提取方面,结合KPCA和t-SNE方法分别提取基础故障库的全局和局部结构特征;而在故障模式诊断方面,为每个随机树赋予不同发言权,从而提出基于专家森林算法的故障诊断方法。

1 面向全局与局部的特征提取方法

首先,笔者从时域、频域、时频域等多个维度出发,选择能够刻画轴承故障状态的初始特征库;而后,依据核主成分分析法(KPCA)提取初始参数中的全局非线性特征,并依据t-SNE挖掘高维特征参数的局部流形结构,提取局部结构特征;最终,获得用于故障诊断的低维特征参数。

1.1 初始特征选取

笔者从时域、频域、时频域等3个维度中选择轴承

故障特征参数作为初始特征库;后续从初始特征库中选择较为敏感的参数作为模式识别参数。采用该方法可以大范围概略地选择时域、频域、时频域特征参数。

初始特征库如表1所示。

表1 初始特征库

类别	编号	参数	编号	参数
时域特征参数	1	最大值	9	均方根幅值
	2	最小值	10	绝对平均值
	3	峰峰值	11	脉冲指标
	4	歪度	12	峰值指标
	5	峭度	13	裕度指标
	6	方差	14	峭度指标
	7	均值幅值	15	波形指标
	8	方根幅值		
频域特征参数	16	频率峭度	19	频率二阶矩
	17	中心频率	20	频率均方根
	18	频率标准偏差		
时频域特征参数	21	IMF ₁ 分量样本熵	24	IMF ₄ 分量样本熵
	22	IMF ₂ 分量样本熵	25	IMF ₅ 分量样本熵
	23	IMF ₃ 分量样本熵		

IMF₁ ~ IMF₅—第1~5层IMF分量

1.2 面向全局特征的特征降维

KPCA依据非线性函数 Φ ,使低维线性不可分的参数映射为高维的线性可分;而后使用PCA降维方法,提取出初始特征库中的全局非线性特征参数^[9]。

笔者将原始数据记为 (x_1, x_2, \dots, x_M) ,使用非线性函数 Φ 将其映射到高维空间 F 后,协方差矩阵表示为:

$$C^F = \frac{1}{M} \sum_{i=1}^M \Phi(x_i) \Phi^T(x_i) \quad (1)$$

式中: C^F —协方差矩阵。

求解协方差矩阵 C^F 的特征值和特征向量^[10],即:

$$C^F \mathbf{v} = \lambda \mathbf{v} \quad (2)$$

式中: λ —矩阵 C^F 的特征值; \mathbf{v} —矩阵 C^F 的特征向量。

特征向量 \mathbf{v} 可以由 $\Phi(x_i)$ 线性表示为:

$$\mathbf{v} = \frac{1}{M} \sum_{i=1}^M \alpha_i \Phi(x_i) \quad (3)$$

式中: α_i —线性系数。

结合式(1~3),则有:

$$\frac{1}{M} \sum_{\gamma=1}^M \alpha_{\gamma} \left[\sum_{w=1}^M (\Phi(x_r) \Phi(x_w) \Phi(x_w) \Phi(x_r)) \right] = \lambda \sum_{\gamma=1}^M (\Phi(x_r) \Phi(x_r)) \quad (4)$$

定义一个 $M \times M$ 维的矩阵 K ,令 $K_{ij} = [\Phi(x_i) \Phi(x_j)]$,则式(2)可以变形为:

$$M \mathbf{K} \boldsymbol{\alpha} = \mathbf{K} \boldsymbol{\alpha} \quad (5)$$

对矩阵 K 的特征值进行排序,为 $\lambda_1 > \lambda_2 > \dots >$

λ_M , 则前 i 个特征值的累积贡献率 η_i 为:

$$\eta_i = \frac{\sum_{k=1}^i \lambda_k}{\sum_{k=1}^M \lambda_k} \quad (6)$$

式(6)中,特征值越大,表明对应的特征向量越能够代表轴承的故障特征。此处,笔者选择累积贡献率不小于 95% 的前 s 个主成分特征。

1.3 面向局部特征的特征降维

t-分布随机邻域嵌入(t-SNE)是一种用于非线性降维的机器学习算法,它将高维数据向低维映射时,最大程度实现了相互间分布概率的相似性,解决了样本数据的拥挤问题^[11]。基于 t-SNE 的参数降维与提取可由以下 6 个步骤来实现。

步骤 1。计算高维联合密度函数。笔者将初始高维数据序列维度设置为 D , 初始数据序列记为 $\mathbf{X} = (x_1, x_2, \dots, x_N) \in \mathbf{R}^D$, 则高维空间中任意两点 x_i, x_j 的距离用概率密度函数衡量^[12], 即:

$$p_{ji} = \frac{\exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma_i^2}\right)}{\sum_{k \neq i} \exp\left(-\frac{\|x_i - x_k\|^2}{2\sigma_i^2}\right)} \quad (7)$$

式中: σ_i — x_i 的高斯方差。

为了避免异常值问题,将高维数据的联合密度函数修正为:

$$p_{ij} = \frac{p_{ij} + p_{ji}}{2N} \quad (8)$$

式中: p_{ij} —修正后的联合密度函数; N —数据序列长度。

步骤 2。初始化低维数据。笔者将蕴含在 \mathbf{X} 中的低维流形记为 $\mathbf{Y} = (y_1, y_2, \dots, y_n) \in \mathbf{R}^d$ 。其中, d 为低维流形维度,且 $d < D$ 。

则低维数据 \mathbf{Y} 使用随机初始化方法,即:

$$\mathbf{Y}(0) = N(0, 10^{-4}\mathbf{I}) \quad (9)$$

式中: $\mathbf{Y}(0)$ —初始化的低维数据; \mathbf{I} — D 维单位向量。

步骤 3。依据 t 分布计算低维数据的概率密度 q_{ij} 为^[13]:

$$q_{ij} = \frac{(1 + \|y_i - y_j\|^2)^{-1}}{\sum_{k \neq i} (1 + \|y_i - y_k\|^2)^{-1}} \quad (10)$$

步骤 4。计算目标函数梯度。以高维分布 P 和低维分布 Q 的相似度为代价函数 C :

$$C = KL(P \parallel Q) = \sum_i \sum_j p_{ij} \log_2 \frac{p_{ij}}{q_{ij}} \quad (11)$$

式中: $KL(P \parallel Q)$ — Y 和 Q 之间的 Kullback-Leibler 散度。

则目标函数梯度为:

$$\frac{\partial C}{\partial y_i} = 4 \sum_j (p_{ij} - q_{ij})(y_i - y_j)(1 + \|y_i - y_j\|^2)^{-1} \quad (12)$$

步骤 5。低维数据的迭代公式。以迭代方式得到低维数据 $\mathbf{Y}(t)$ 为:

$$\mathbf{Y}(t) = \mathbf{Y}(t-1) + \eta \frac{\partial C}{\partial \mathbf{Y}} + \mu(t)[\mathbf{Y}(t-1) - \mathbf{Y}(t-2)] \quad (13)$$

式中: t —迭代次数; η —学习效率; $\mu(t)$ —动量因子。

步骤 6。重复步骤 3 ~ 步骤 5 直到达到最大迭代次数 T , 而后得到低维数据 $\mathbf{Y}(T)$ 。

按照以上步骤,可以从高维数据中提取局部的流形结构特征,得到低维特征参数。

1.4 特征参数降维步骤与评价参数

基于 KPCA 全局特征与 t-SNE 局部特征的特征参数降维步骤为:

步骤 1。采集轴承的原始振动数据,计算表 1 中的参数构造原始故障特征参数,而后进行参数归一化,得到初始故障特征库 \mathbf{X} ;

步骤 2。以径向基函数为核函数,使用 KPCA 进行参数降维,得到贡献率不小于 95% 的特征参数,以及基于全局特征的降维参数 \mathbf{X}_1 ;

步骤 3。以 \mathbf{X}_1 为高维数据,使用 t-SNE 对数据进行降维处理,得到基于局部流形结构特征的降维特征参数 \mathbf{X}_2 。

故障特征的提取效果可以采用类间间距 S_w 和类内间距 S_b 进行评价。笔者将原始序列记为 $\mathbf{X} = (x_1, x_2, \dots, x_N) \in \mathbf{R}^D$ 。

假设该数据序列具有 L 个模式类,第 i 类的样本数量为 N_i , 则类间间距 S_w 和类内间距 S_b 分别为:

$$S_w = \frac{1}{N} \sum_{i=1}^L \sum_{j=1}^{N_i} [\Phi(x_{ij}) - m_i][\Phi(x_{ij}) - m_i]^T$$

$$S_b = \sum_{i=1}^L \frac{N_i}{N} (m_i - \bar{m})(m_i - \bar{m})^T \quad (14)$$

式中: $\Phi(x_{ij})$ —第 i 模式类的样本矢量 j ; m_i —第 i 模式类的样本均值; \bar{m} —所有样本均值; S_w —描述类内样本的紧密程度,其值越小表示样本聚集度越好; S_b —描述不同类的分离程度,其值越大表示类间的区分度越明显。

综合两个参数,笔者使用 $\frac{S_b}{S_w}$ 作为综合评价参数,其值越大,表明参数降维效果越好。

2 基于专家森林算法的故障识别

随机森林算法中一棵树为一个决策单元,多个决策树组成一个随机森林,随机森林算法中森林的决策结果为多数决策树的输出结果^[15]。这种决策方式充分发挥了决策树的民主作用,但是却忽略了决策树的

个体差异,也即忽略了决策树的专家属性差异。为了解决这一问题,笔者提出了一种专家森林算法。

2.1 随机森林算法

笔者将原始数据集记为 D , 样本数量记为 N' , 输入特征数量记为 M' , 分类标签记为 Y 。随机森林的构造包括抽样、决策树训练、决策树决策、森林决策等步骤^[14]。

(1) 抽样。使用 bootstrap 抽样法从原始数据集 D 中有放回地抽取 K 个训练样本, 称为 bootstrap 样本^[16];

(2) 决策树训练。基于分类回归树构建决策树, 在决策树的每个节点位置, 从所有输入特征中随机选择 m 个作为该节点的分裂特征集, 而后依据基尼指数最小化准则选择最优分裂特征和切分点, 从而将训练样本划分到两个子节点中。重复以上步骤, 直至决策树训练完毕;

(3) 决策树决策。使用 bootstrap 样本按照上述步骤训练决策树, 训练完毕的决策树组成一个随机森林 $\{t_i, i=1, 2, \dots, K\}$, t_i 表示决策树 i 。将测试样本 x 输入到该随机森林中, 得到各决策树的决策结果 $\{t_i(x), i=1, 2, \dots, K\}$;

(4) 随机森林决策。随机森林的决策方式较为简单, 一般取决策树输出的众数作为随机森林的决策结果, 即^[17]:

$$T(x) = \operatorname{argmax}_{y} \sum_{i=1}^K (t_i(x) = y) \quad (15)$$

式中: $T(x)$ —随机森林针对样本 x 的决策结果。

2.2 专家森林算法

如前所述, 为决策树赋予完全相同的投票权忽略了个体之间的专家属性差异, 即这是一种将专家决策和普通人决策同等视之的决策方法, 因此其存在明显的不合理。

为了解决这一问题, 笔者提出了专家森林算法, 其基本思想为: 在决策树训练完毕后, 增加一个预测过程, 根据决策树的预测准确率对决策树赋予不同的专家属性和专家权重。

在传统随机森林算法^[18]中, 抽样的 K 个 bootstrap 样本全部为训练集。而在专家森林算法中, 以随机方式选择 $0.8K$ 个 bootstrap 样本作为训练集, 另外 $0.2K$ 个 bootstrap 样本作为预测集。

决策树 i 的预测准确率记为 R_i , 为:

$$R_i = \frac{K_{\text{correct}}}{0.2K} \quad (16)$$

式中: K_{correct} —预测集中决策正确的样本数量; $0.2K$ —预测集中的样本总数。

毫无疑问, 决策树预测的准确率可以代表决策树的专家属性。预测准确率越高, 表示决策树的专家性越强, 其做出的决策信服力也就越强。

为了让专家决策树充分发挥专家作用, 笔者依据其预测准确率赋予其不同权重, 即:

$$w_i = \frac{R_i}{\sum_i R_i} \quad (17)$$

式中: w_i —决策树 i 的专家权重。

专家森林根据加权决策值做出最终决定, 为:

$$T_{\text{ex}}(x) = \operatorname{argmax}_i \sum_i w_i t_i(x) \quad (18)$$

式中: $T_{\text{ex}}(x)$ —专家森林决策结果。

3 实验与结果分析

3.1 实验设置与特征提取

此处笔者以美国凯斯西储大学的轴承实验公开数据作为数据来源, 选择 SKF6205 型轴承试验数据; 使用电火花加工技术在内圈、外圈和滚动体上加工出点蚀故障, 障碍点直径为 0.1778 mm , 数据采样频率为 48 kHz 。

实验中, 分正常状态、内圈故障、外圈故障、滚动体故障等 4 种状态, 每种状态下各包含 200 个样本, 共 800 个样本, 每个样本随机截取 0.1 s 的原始数据。

首先, 验证轴承故障特征提取方法的优劣。为了进行比较, 笔者同时使用 KPCA、t-SNE、KPCA 与 t-SNE 结合的特征参数降维与提取方法。

3 种方法对应的参数降维后的空间分布如图 1 所示。

为了量化地比较不同方法提取特征的优劣, 笔者使用 1.4 节中的综合评价参数 $\frac{S_b}{S_w}$ 为评价指标, 其计算结果如图 2 所示。

由图 2 可知:

使用 KPCA 与 t-SNE 相结合提取的故障特征指标参数值最大, 其次为 KPCA 方法和 t-SNE 方法;

参数指标值与图 1 特征分布相对应, KPCA + t-SNE 提取的特征不仅类与类之间区分明显, 而且类内样本的聚集度较好;

KPCA 提取的特征类间区分也较好, 但是类内样本的聚集度明显差于 KPCA + t-SNE 组合法;

T-SNE 提取的外圈故障而后滚动体故障间还存在交叉现象, 因此其指标参数最小。

从理论上讲, KPCA 法只提取了故障特征的全局特征, t-SNE 只提取了故障特征的局部流形结构特征; 而 KPCA + t-SNE 方法充分挖掘了故障特征的全局和

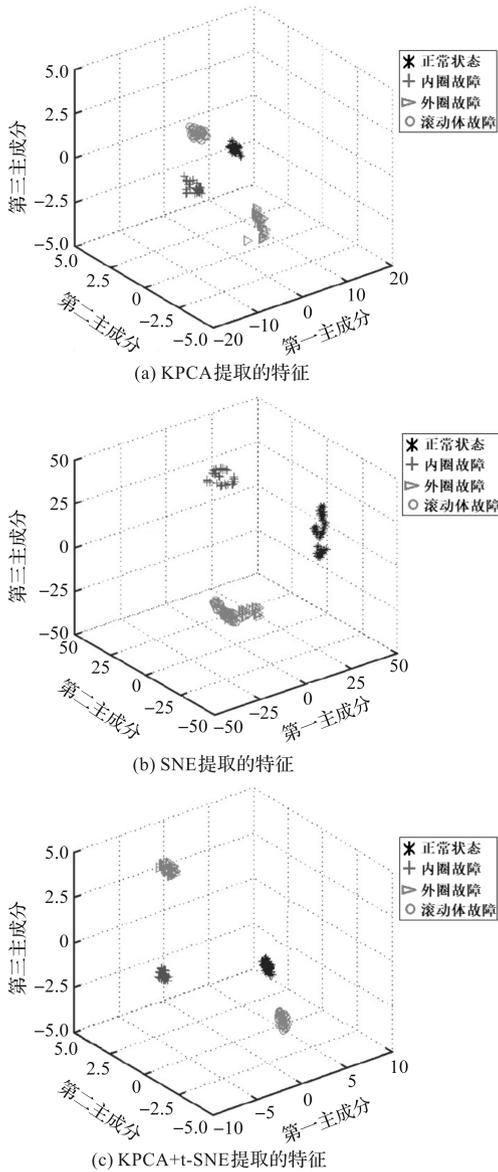


图 1 不同方法提取的特征

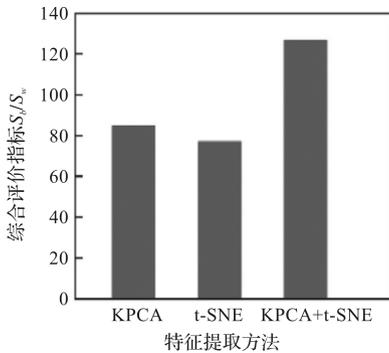


图 2 不同提取方法的评价指标

局部结构特征,因此提取效果好于另外两种方法。

3.2 故障模式诊断结果

笔者从每个状态的 200 组样本中抽取 160 组作为 Bootstrap 样本。在传统随机森林算法中,该 160 组 Bootstrap 样本直接用于决策树训练。在专家森林算法中,随机选择其中的 80% (即 128 组)作为训练集,其

余的 20% (即 32 组)作为预测测试集。

待随机森林算法和专家森林算法训练完毕后,笔者使用随机森林算法和专家森林算法分别对剩余的 $40 \times 4 = 160$ 组测试样本进行故障诊断,其结果如图 3 所示。

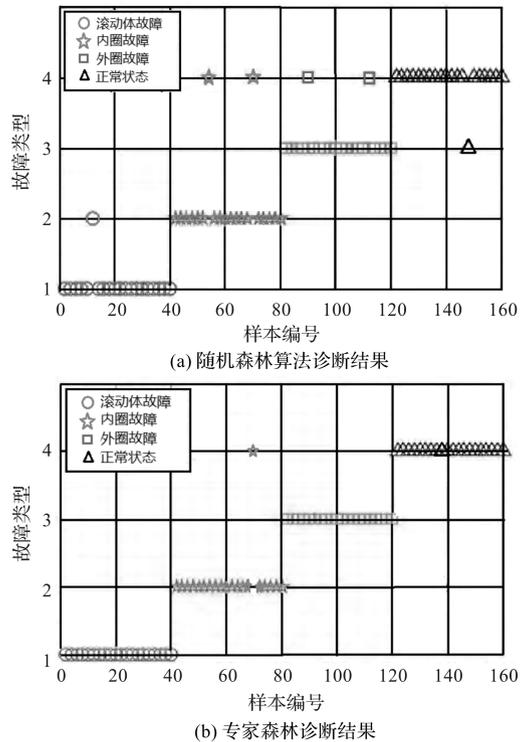


图 3 两种森林算法的诊断结果

图 3 所示的实验中,随机森林算法的诊断准确率为 96.25%,专家森林算法的诊断准确率为 99.38%。

在本次实验中,专家森林的诊断准确率高于随机森林算法。为了进行更加有力的比较,笔者按照上述步骤重复实验 10 次,每次实验抽取的训练样本和测试样本不同,统计 10 次实验的诊断准确率参数。

两种森林算法诊断准确率如表 2 所示。

表 2 两种森林算法诊断准确率

算法	准确率均值	准确率标准差
随机森林	96.14%	3.26%
专家森林	99.48%	0.87%

由表 2 可知:

随机森林算法的诊断准确率均值为 96.14%,标准差为 3.26%;而专家森林算法的诊断准确率为 99.48%,比随机森林算法提高了 3.47%;专家森林算法诊断准确率标准差为 0.87%,远小于随机森林算法,说明专家森林算法诊断结果更加稳定。

以上数据说明,专家森林算法的故障诊断准确率高于随机森林算法,且诊断稳定性好于随机森林算法。

这是因为专家森林算法中,在训练阶段对决策树

的专家属性进行了预测试,能够较为准确地评价决策树的专家属性,从而依据专家属性赋予不同的专家权值,使其发言权与自身诊断能力成正比;而随机森林将所有决策树视为同等决策权,忽略了个体间的差异,因此随机森林算法的诊断性能差于专家森林算法。

4 结束语

针对特征参数敏感度问题和随机森林无差别对待随机树的问题,笔者从故障特征提取和故障模式识别两个角度对其进行了研究,即在故障特征提取方面,结合 KPCA 和 t-SNE 方法分别提取基础故障库的全局和局部结构特征;在故障诊断方面,为决策树赋予专家属性和专家权值,从而提出了专家森林算法。

经验证得出以下研究结论:

(1) 基于 KPCA 与 t-SNE 结合方法提取的故障特征优于两种方法独立提取的特征;

(2) 通过故障特征提取,不仅可以降低特征维度,降低计算量,而且可以提高特征向量对故障敏感程度;

(3) 专家森林算法由于在随机树上赋予了专家属性,因此故障诊断准确率高于随机森林算法。

从轴承故障诊断的研究热点和发展趋势看,在今后的工作中笔者可以展开以下 3 个方面的研究:

(1) 研究高敏感特征提取方法,使故障特征对故障模式更加敏感;

(2) 研究更加准确的分类方法,使模式识别更加精准;

(3) 研究基于深度学习的故障特征提取与模式识别一体化方法。

参考文献 (References):

- [1] 唐泽娴,林建辉,张 兵,等. 结合频谱聚类与经验小波的轴承故障诊断方法[J]. 机械设计与制造,2021(5):144-148.
- [2] 金 京,刘 畅,兰雨涛,等. 基于 LMD 和 MOMEDA 的滚动轴承早期故障特征提取研究[J]. 机电工程,2021,38(3):276-285.
- [3] 王一鹏,陈学振,李连玉. 基于小波包混合特征和支持向量机的机床主轴轴承故障诊断研究[J]. 电子测量与仪器学报,2021,35(2):59-64.
- [4] THOM H T, YUAN C M, TUAN V Q. A novel perturbed particle swarm optimization-based support vector machine for

fault diagnosis in power distribution systems[J]. *Turkish Journal of Electrical Engineering and Computer Sciences*,2018,26(1):518-529.

- [5] 刘自然,李 谦,颜丙生,等. 堆叠稀疏自编码深度神经网络算法及其在滚动轴承故障诊断中的应用[J]. 机床与液压,2020,48(23):208-213.
- [6] 范春吻,吴守鹏,刘晓文,等. 基于小波包变换与随机森林的滚动轴承故障特征分析方法[J]. 机械设计与制造,2020(10):59-63,70.
- [7] 孙 岩,彭高亮. 改进胶囊网络的滚动轴承故障诊断方法[J]. 哈尔滨工业大学学报,2021,53(1):23-28.
- [8] 王金东,陈 新,赵海洋,等. 基于精细复合多尺度模糊熵的往复压缩轴承间隙故障特征分析方法[J]. 机床与液压,2021,49(16):185-190.
- [9] 梁章章,黄星舒,吴丽娟,等. 基于 KPCA 和改进 K-means 的电力负荷曲线聚类方法[J]. 华南理工大学学报(自然科学版),2020,48(6):143-150.
- [10] 朱 翔,谢 峰. 基于核主成分分析 BP_Ada Boost 算法的数控铣床故障诊断[J]. 机械强度,2019,41(6):1292-1297.
- [11] JOO H, KIM J, KWAK J, et al. Improvement of regional clustering using flood control characteristics and t-SNE of machine learning[J]. *Korean Society of Hazard Mitigation*,2020,20(3):247-257.
- [12] HAMID Y, SUGUMARAN M. A t-SNE based non-linear dimension reduction for network intrusion detection[J]. *International Journal of Information Technology*,2020,12(1):125-134.
- [13] 胡启国,杜春超,罗 棚. 基于 t-SNE 和核马氏距离的滚动轴承健康状态评估[J]. 组合机床与自动化加工技术,2021(8):57-61.
- [14] 黄 瑾,刘 洋,钟麦英,等. 利用随机森林算法的卫星控制系统故障诊断[J]. 宇航学报,2021,42(4):513-521.
- [15] JANITZA S, TUTZ G, BOULESTEIX A L. Random forest for ordinal responses: prediction and variable selection[J]. *Computational Statistics & Data Analysis*,2016(96):57-73.
- [16] RATHER T A, KUMAR S, KHAN J A. Multi-scale habitat modelling and predicting change in the distribution of tiger and leopard using random forest algorithm[J]. *Scientific Reports*,2020,10(1):11473.
- [17] 白小曼,冯永祥,李雷孝,等. 针对城市道路拥堵的优化随机森林预测模型[J]. 科学技术与工程,2021,21(26):11205-11211.
- [18] 蔡永智,唐 捷,危阜胜,等. 基于随机森林模型的台区相序识别方法[J]. 机电工程技术,2021,50(12):50-53.

[编辑:雷 敏]

本文引用格式:

庄 燕. 轴承故障的全视角特征提取与模式诊断方法[J]. 机电工程,2022,39(3):344-349.

ZHUANG Yan. Whole view feature extraction and mode diagnosis method for bearing faults[J]. *Journal of Mechanical & Electrical Engineering*,2022,39(3):344-349.

《机电工程》杂志: <http://www.meem.com.cn>