

基于节点优化型 DAG-LDM 的机组滚动轴承故障诊断方法

刘朝华^{1,2†}, 孟旭东¹, 陆碧良¹, 李小花¹, 童成意³

(1. 湖南科技大学 信息与电气工程学院, 湖南湘潭 411201; 2. 湖南大学 汽车车身先进设计制造
国家重点实验室, 长沙 410082; 3. 长沙师范学院 信息科学与工程学院, 长沙 410100)

摘要: 滚动轴承作为风电机组的关键部件, 对于整个机组的安全运行起着决定性作用. 针对机组滚动轴承故障诊断问题, 提出一种节点优化型有向无环图大间隔分布机 (O-DAG-LDM) 的故障诊断方法. 结合 DAG 多分类扩展性能与 LDM 二分类器泛化性能的优点, 构建一种面向滚动轴承故障诊断的 DAG 结构扩展式 LDM 多分类器方法. 在 DAG-LDM 算法框架下, 利用优化算法对 DAG 节点进行优化排列以减小随机排布引起的累积误差, 提高 LDM 故障分类准确率. 实验表明, 与其他主流智能诊断方法相比, 所提出的节点优化型 DAG-LDM 故障诊断方法具有较高的准确率和更好的抗噪性能.

关键词: 有向无环图; 大间隔分布机; 多分类器; 节点优化; 滚动轴承; 故障诊断

中图分类号: TP13

文献标志码: A

Fault diagnosis method of wind turbine rolling bearing based on node optimized DAG-LDM

LIU Zhao-hua^{1,2†}, MENG Xu-dong¹, LU Bi-liang¹, LI Xiao-hua¹, TONG Cheng-yi³

(1. School of Information and Electrical Engineering, Hunan University of Science and Technology, Xiangtan 411201, China; 2. State Key Laboratory of Advanced Design and Manufacturing for Vehicle Body, Changsha 410082, China; 3. College of Information Science and Engineering, Changsha Normal University, Changsha 410100, China)

Abstract: As a key component, the rolling bearing plays a decisive role in the safe operation of the whole wind turbine. To solve the problem of fault diagnosis in rolling bearings, a fault diagnosis method based on optimized directed acyclic graph combing with large margin distribution machine (O-DAG-LDM) is proposed. Combining the advantages of DAG multi-class scalable features with the generalization performance of LDM two-classifier, a DAG structure extended LDM multiple classifier method for rolling bearing fault diagnosis is constructed. In the framework of the DAG-LDM method, a node optimization algorithm is used to optimize the DAG nodes to reduce the cumulative error caused by random permutation, and improve the accuracy of LDM fault classification. The experiment shows that the proposed O-DAG-LDM method for fault diagnosis has higher accuracy and better capability of anti-noise immunity in comparison with other mainstream intelligent diagnosis methods.

Keywords: directed acyclic graph; large margin distribution machine; multiple classifier; node optimization; rolling bearing; fault diagnosis

0 引言

风力发电作为一种清洁绿色能源受到全球各国的高度重视和大力发展. 随着装机容量的不断攀升, 风电装备正朝着大型化、复杂化、智能化的方向发展. 风机以高山、海上等偏远恶劣运行环境为主, 与此同时, 风电机组的故障发生率也随之升高. 滚动轴承作为机组的关键部件, 对于整个风电系统的安全运行起

着决定性作用. 风力发电过程中风速与负荷的交变使轴承不断受到载荷冲击, 滚动轴承成为风电机组中故障发生率较高的几种部件之一, 统计表明, 轴承故障率占据总故障的 40%^[1]. 滚动轴承的故障诊断成为当前风电机组故障诊断领域的重要方向之一. 利用滚动轴承的振动信号进行状态监测与故障诊断是常用方式, 其数据通常具有非线性非平稳的特性, 相

收稿日期: 2017-12-06; 修回日期: 2018-03-16.

基金项目: 国家自然科学基金项目 (61503134, 61573299); 国家自然科学基金青年项目 (61503132); 湖南省自然科学基金项目 (2018JJ2134, 2016JJ4003); 湖南大学汽车车身先进设计制造国家重点实验开放基金项目 (31715010); 湖南省科技人才专项湖湘青年英才项目 (2018RS3095).

责任编辑: 魏秀琨.

†通讯作者. E-mail: zhaohualiu2009@hotmail.com.

较于线性平稳信号更加难以处理.随着现代信号处理技术与智能模式识别理论的深入发展,基于信号处理方法和基于机器学习方法的滚动轴承故障诊断方法相继提出.

小波技术因具有较好的信号提取优势被成功应用到滚动轴承故障诊断中.文献[2]提出了基于小波的滚动轴承故障信号特征提取方法,并运用主成分分析(Principal component analysis, PCA)对故障特征进行降维,最后利用支持向量机(SVM)进行故障分类.由于小波基难以选取,文献[3]提出了稀疏性小波变换模型,通过稀疏指导函数自动建立小波变换所需的傅立叶窗口并应用于滚动轴承的故障诊断,取得了较好的诊断效果.

短时傅里叶变换具有处理非平稳信号的优势,被研究人员应用到轴承故障诊断中.文献[4]首先通过短时傅里叶变换(Short term fourier transform, STFT)将原始信号进行时频分解,然后运用非负矩阵因子分解技术对数据进行映射,从时频信号中提取故障特征;文献[5]对原始数据运用短时傅里叶变换(STFT)进行处理,得到简单的频谱图,再利用优化的深度神经网络对频谱图进行特征提取和故障诊断.然而,研究表明,短时傅里叶变换存在窗函数时间与频率分辨率不能同时达到最优的缺陷.以傅里叶变换为基础的经验模态分解(Empirical mode decomposition, EMD)方法被研究人员引入到轴承故障诊断中.文献[6]将EMD与Choi-Williams分布的结合研究应用于滚动轴承故障特征提取,该方法利用EMD将原始信号分解为一系列IMF(Internal modal functions),然后利用Choi-Williams分布对每一个IMF进行时频分析并进行线性叠加,得到信号特征.然而,EMD存在模式混叠效应,文献[7]利用集合经验模态分解方法(Ensemble empirical mode decomposition, EEMD)对信号寻找包含主要信息的内在模态函数IMF分量,接着采用峭度值结合相关系数选取有效IMF分量组成特征矩阵并进行奇异值分解,从而得到特征向量.该方法抑制了频率混叠和干扰,能够准确提取故障特征.

为提取非平稳信号分量特征,文献[8]通过最小熵反褶积(MED)对信号进行处理,再利用功率谱峰值(MPSK)指导滤波器的长度以实现滚动轴承的故障诊断;文献[9]提出了一种比MED效果更好的算法,利用改进的非局部平均去噪(NL-means)算法对信号进行处理来增强信号特征,以此在强噪声环境下进行故障诊断;文献[10]通过自适应局部迭代滤波(ALIF)技术将原始信号分解成多个固定分量,再通过包络调解来提取特征,该方法在提取非平稳信号分量和抑制模式混合方面效果显著.以上都是基于信号

处理技术的轴承故障诊断方法,其理论基础源于传统统计学,其分类精度受限于数据样本.

人们利用深度神经网络强大的非线性表征能力,提出了基于深度神经网络的滚动轴承故障诊断.如文献[11]利用深度卷积信念网络结合自编码器对滚动轴承进行故障诊断,利用指数平均数指标(EMA)对网络性能进行优化以提高诊断效率;文献[12]采用深度玻尔兹曼机、深度信念网络和堆栈自编码器分别对滚动轴承进行故障诊断,实现了原始数据特征有效提取和单模特征诊断.小波分解技术、经验模态分解技术、神经网络方法都是处理非平稳信号常用的方法,但是它们依旧存在着不足之处.首先,对于如何选取最佳小波基目前还没有通用理论,往往要具体分析信号的特征,并通过试凑方法来寻找最适宜小波基,浪费大量人力物力.同时,轴承故障特征往往存在于高频部分,然而小波分解到高频部分不再分解,这导致难以完全利用有限特征来完成故障诊断.在上文已经提到过经验EMD和EEMD都存在模式混叠效应,EEMD虽然能够抑制模式混叠,但是不能完全避免,并且两种算法的时间复杂度都很高.神经网络虽然具有优异的特征学习能力,但目前深度神经网络不仅存在结构与参数难以确定、算法时间开销大等问题,而且容易陷入局部极小值困境.

相较于神经网络,支持向量机(SVM)可以有效得到全局最优解,有效避免局部极小值问题,同时SVM不仅能够处理高维数据,而且有很好的小样本学习能力.支持向量机是基于统计学习理论而提出的机器学习方法,其在数据分类与模式识别中得到广泛应用.文献[13]提出了一种复合多尺度模糊熵(CMFE)和综合支持向量机(ESVM)的新型滚动轴承故障诊断方法.该方法通过CMFE对故障信号进行特征提取,然后运用ESVM对故障进行分类.基于间隔分布正则化的大间隔分布机(LDM),通过最大化间隔分布增强了模型的泛化性能,并取得了优于SVM等先进方法的分类性能^[14].由于具有较好的泛化性能,LDM开始被应用到智能分类和模式识别中,如一些研究人员将LDM应用于手写音乐符号的分类^[15]中,取得了很好的分类效果.但基本LDM只是面向二分类器构建的,如进行多分类时,必须训练多个分类器重新构建.然而,实际测量的数据往往是多类别的,如何将LDM应用于多类别分类是一种研究趋势.受图论中的有向无环图(Directed acyclic graph, DAG)启发,文献[16]提出了基于DAG的能够实现样本不对称、无盲区可优化结构的多分类扩展策略.该思想给DAG提供了一种有效的多分类扩展方案.针对风电机组滚动轴承故障诊断问题,本文提出一种节点优化型有

向无环图大间隔分布机(O-DAG-LDM)故障诊断方法. 在DAG-LDM算法框架下,利用节点优化算法对DAG节点进行优化排列以提高数据划分精度. 实验结果表明,所提出方法不需要对信号进行分解预处理且具有较高的故障诊断效率.

1 基于优化型DAG-LDM的多分类器

尽管LDM在处理二分类问题时效果很好,但是对于多类对象却无能为力. 本文通过有向无环图(Directed acyclic graph, DAG)结构将LDM推广到DAG-LDM,进一步构建DAG结构扩展式LDM多分类器方法,并对DAG结构进行优化排列,将其应用于解决滚动轴承故障分类.

1.1 支持向量机(SVM)

支持向量机是通过构造核函数将低维线性不可分的数据投影到高维空间,形成一个线性可分的数据集,并寻求最大间隔分类超平面对数据进行分类^[17]. 该方法通过求解一个线性约束的二次规划问题得到全局的最优解,具体流程为:在一个内积空间 H 中,任何一个超平面可以表示为

$$\{\omega^T x + b = 0 | x \in H, b \in R\}, \quad (1)$$

其中 ω 为一个垂直于超平面的线性预测器向量. 设样本特征向量为 $\{x_1, x_2, \dots, x_i\}$,分类标签为 $\{y_1, y_2, \dots, y_i\}$,当 x_i 属于类1时, y_i 为1,当 x_i 属于类2时, y_i 为-1. 最优分类平面就是要求分类面将两类正确分开后,分类间隔最大

$$\min_{\omega} \varphi(\omega) = \frac{1}{2} \|\omega\|^2 = \frac{1}{2} (\omega^T \cdot \omega);$$

$$\text{s.t. } y_i [(\omega \cdot x_i) + b] \geq 1. \quad (2)$$

其中 $i = 1, 2, \dots, n$. 当训练样本存在相互交叉不能准确地完全确定分类情形时,通过引入拉格朗日函数,将该问题由二次规划问题转化为其对偶问题. 其目标函数为

$$\begin{aligned} \min_{\omega, \zeta} \quad & \frac{1}{2} \omega^T \omega + C \sum_{i=1}^m \zeta_i; \\ \text{s.t.} \quad & y_i \omega^T \varphi(x_i) \geq 1 - \zeta_i, \\ & \zeta_i \geq 0, \quad i = 1, 2, \dots, m. \end{aligned} \quad (3)$$

其中: ω 为线性预测器; $\varphi(x)$ 为映射特征; C 为惩罚系数,用来平衡损失误差和模型复杂度; ζ 为松弛变量. 通过求解一个线性约束型二次规划问题的最优解,确保该方法能够在少量样本下得到较好的分类结果.

1.2 大间隔分布机(LDM)

由上述内容可知,SVM只优化了最小间隔,并没有优化间隔分布,理论研究表明:间隔分布(包括间隔均值和间隔方差)对支持向量机的泛化性能具有决

定性作用^[14]. 间隔的分布由间隔方差和间隔均值表示^[18],即

$$L_i = y_i \omega^T \varphi(x_i), \quad \forall i = 1, 2, \dots, m. \quad (4)$$

则间隔均值表示为

$$\bar{L} = \sum_{i=1}^m y_i \omega^T \varphi(x_i) = \frac{1}{m} (Xy)^T \omega, \quad (5)$$

间隔方差为

$$\begin{aligned} \hat{L} &= \frac{1}{m^2} \sum_{i=1}^m \sum_{j=1}^m (y_i \omega^T \varphi(x_i) - y_j \omega^T \varphi(x_j))^2 = \\ &= \frac{2}{m^2} (m\omega^T X X^T \omega - \omega^T X y y^T X^T \omega). \end{aligned} \quad (6)$$

在这两个定义的基础上建立大间隔分布机模型(LDM),通过最大化间隔分布(最大化间隔均值和最小化间隔方差)来获得强泛化性能,其目标函数为

$$\begin{aligned} \min_{\omega, \zeta} \quad & \frac{1}{2} \omega^T \omega + \alpha_1 \hat{L} - \alpha_2 \bar{L} + C \sum_{i=1}^m \zeta_i; \\ \text{s.t.} \quad & y_i \omega^T \varphi(x_i) \geq 1 - \zeta_i, \\ & \zeta_i \geq 0, \quad i = 1, 2, \dots, m. \end{aligned} \quad (7)$$

其中 C, α_1, α_2 为平衡参数. 将间隔均值(5)和间隔方差(6)代入式(7),则目标函数转化为

$$\begin{aligned} \min_{\omega, \zeta} \quad & \frac{1}{2} \omega^T \omega + \frac{2\alpha_1}{m^2} (m\omega^T X X^T \omega - \omega^T X y y^T X^T \omega) - \\ & \alpha_2 \frac{1}{m} (Xy)^T \omega + C \sum_{i=1}^m \zeta_i; \\ \text{s.t.} \quad & y_i \omega^T \varphi(x_i) \geq 1 - \zeta_i, \quad \zeta_i \geq 0, \quad i = 1, 2, \dots, m. \end{aligned} \quad (8)$$

从上式可以看出,当 $\alpha_1 = \alpha_2 = 0$ 时,LDM完全退化为支持向量机. 由此可知,LDM优化了间隔的分布,使分类面更好地符合样本的分布情况,这就使两类样本均值的间隔加大,这与实际工程故障特性相符合,能够有效提高分类的准确性,如图1所示.

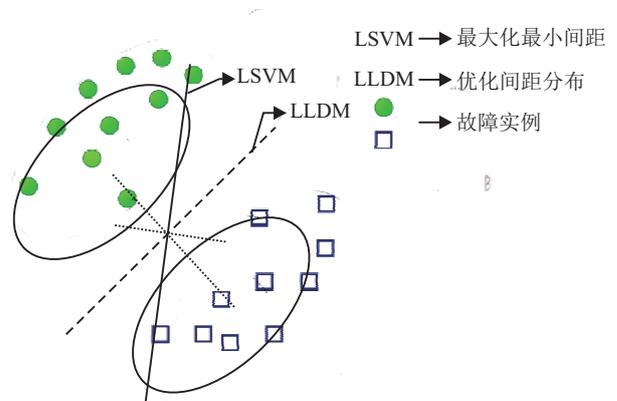


图1 SVM和LDM的示例

由图1可知,与只优化最小间隔SVM相比,LDM优化了间隔分布,具有更强的泛化性能. 与SVM一样,LDM也可以通过构造核函数将低维不可分的数

据映射到高维空间,从而完成非线性分类. 常见的核函数有线性核函数、多项式核函数、径向基核函数,其中径向基函数表示如下:

$$K(x, x_i) = \exp(-g\|x - x_i\|^2), g > 0. \quad (9)$$

其中: x 为样本点, x_i 为样本数据中心点. LDM是针对两类问题构建的,在多分类效果上表现不好,这就需要需要一个分类结构来扩展其多分类任务.

1.3 优化型DAG-LDM的多分类器算法原理

LDM是针对两类问题构建的,如处理多分类则需要进一步扩展. 受图论中的有向无环图(Directed acyclic graph, DAG)启发, Platt等^[16]研究表明, DAG可以实现样本不对称、无盲区可优化结构的多分类扩展策略. 对于一个给定空间 X ,存在一组函数集 $F = f \rightarrow \{-1, 1\}$,基于 DAG-LDM的 N 分类器 F 由 $K(K = N(N-1)/2)$ 个二分类器分布在 DAG 拓扑上的 k 层结构上,每个节点对应一个 LDM 函数,所有节点构成一个二叉树结构,具体为:顶端为1个根节点,第2层拥有两个节点,以此演化,第 j 层拥有 j 个节点. 第 j 层的第 i 个节点 (i, j) 与第 $j+1$ 层的第 i 个节点 $(i, j+1)$ 以及第 $i+1$ 个节点 $(i+1, j+1)$ 相连. 通过父代和子代两类样本的训练,每个节点排除其中一类,以此类推,直到最底层 n 个叶节点. 这种决策方法在不增加决策时间复杂度的情况下,为不同数据选取不同的划分路径,提高了划分精度. 基于 DAG 的4类数据决策流程如图2所示(图2中的标识Not i 表示非 i 类).

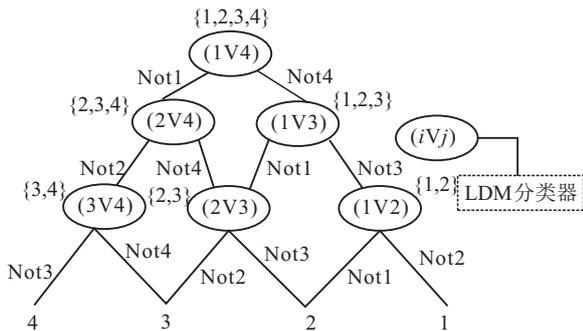


图2 4类问题的DAG-LDM结构

然而,DAG结构排列不是唯一的,不同的DAG结构影响不同DAG-LDM多分类器性能. 由于DAG结构中的节点是随机排列的,不同的节点排列组合会对样本决策路径产生影响,进而影响分类结果^[19]. 利用LDM对故障数据进行两两训练,按结果精度从高到低排列DAG结构中节点的顺序,以此优化DAG结构,减小以往随机排列的累积误差. 对DAG结构的根节点和其他节点排序进行优化,首先为每一层建立备选节点集合,选择下层集合中精度最高的节点当作当前

层节点的下层节点,以此来优化DAG图层的拓扑结构,减少累积误差来提高对数据划分的容错能力和划分精度. DAG节点优化算法步骤如下.

- Step 1: 选取适量训练数据和测试数据进行计算;
- Step 2: 对4类故障数据分别进行两两训练,并且保存模型;
- Step 3: 利用训练好的模型对测试数据进行预测,并计算准确率;
- Step 4: 按预测结果精度从高到低依次对DAG结构中节点进行排序,从而优化DAG结构.

2 基于优化型DAG-LDM的滚动轴承故障诊断

将所提出的优化型DAG-LDM多分类器方法应用于滚动轴承故障诊断中, O-DAG-LDM故障诊断模型构建流程如图3所示.

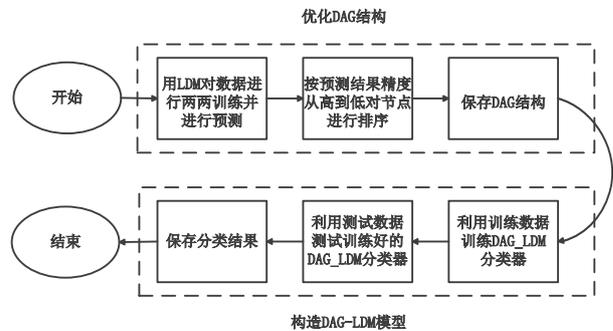


图3 O-DAG-LDM故障诊断模型流程

通过节点优化算法将DAG结构优化并保存后,将LDM算法布置于DAG节点上,这样构成了DAG-LDM故障诊断系统,再利用训练数据对DAG-LDM进行训练,最后用测试数据来测试系统的性能. 算法步骤如下.

- Step 1: 对原始数据进行小波处理,消除噪声影响;
- Step 2: 计算节点个数,即需要的二分类器的个数 $N_{classifier}$,具体表示为

$$N_{classifier} = m(m - 1)/2; \quad (10)$$

- Step 3: 对每个LDM二分类器进行训练和测试并保存测试结果;
- Step 4: 选出精度最高的节点作为根节点,同时按精度排序从上至下依次将LDM二分类器保存在如图2所示的DAG结构拓扑图中;
- Step 5: 将训练数据输入到建立好的模型中,然后对数据两两训练,最后保存分类器;
- Step 6: 选取测试数据,然后调用Step 5保存好的分类器进行分类,输出类别结果.

3 实验与结果分析

3.1 数据选择

为验证基于优化型 DAG-LDM 的多分类器故障诊断模型的效果,利用美国凯斯西储大学实验室的轴承数据^[20]进行实验测试.该平台可以模拟风电机组传动系统,具体为:测试轴承型号为6205-2RS-JEM-SKF深沟球轴承,使用电火花加工技术在轴承上布置单点故障.电机旋转速度为1748 rad/min,采样频率为12 kHz,故障尺寸为7 mils (1mil=0.001 inches).4种工况数据为:正常状态(Normal, NR)数据、内圈故障(Inner race fault, IRF)、外圈故障(Outer race fault, ORF)和滚动体故障(Ball fault, BF).实验样本总量是2000个,4种不同状态样本各500个,每个样本的长度为100,样本编号依次为NR:1-500,IRF:501-1000,ORF:1001-1500,BF:1501-2000.滚动轴承各种状态的震动时域波形如图4所示.

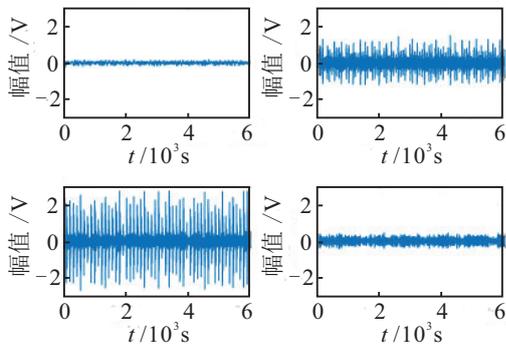


图4 滚动轴承各种状态的振动时域波形

3.2 实验训练数据

从图4中可以看出,NC数据和BF数据没有明显的规律,两者的随机性较强,自相似性较低.故障频率分量混杂于其他的冲击信号之中,强度较弱,很不明显,无法有效辨别. IRF数据和ORF数据的轴承故障冲击信号没有完全被噪声淹没,在某些频段上有固定的周期,自相似性较高,而且在所有节点中,包含这两种数据的节点精度最高,因此将IRF数据和ORF数据置于DAG顶端根节点优先进行分类,以免累积误差增加.按照文中所提出的优化DAG的模型顺序排列,对于所选取的4类故障需要训练6(即 $4 \times 3/2$)个LDM二分类器.

3.3 实验参数设置

在本实验中涉及的参数集合 $\{c, g, \alpha_1, \alpha_2\}$ 的范围设定为 $[2^{-10}, 2^{10}]$,文中运用K折交叉验证对参数进行寻优.在实验中首先将故障数据划分为6份,选取其中的5份作为训练集,保留1份作为验证数据集.文中通过6次统计实验选取目标函数最优时对应的参数.实验选取参数如表1所示.

表1 试验参数选取

序号	参数名称	符号	数值
1	惩罚系数	c	2
2	核函数的参数	g	5
3	方差系数	α_1	0.1
4	间隔	α_2	0.1

3.4 实验分析

为了验证文中提出的面向滚动轴承故障诊断的O-DAG-LDM多分类器方法的有效性,将O-DAG-LDM方法与主流的智能分类方法对比,如:极限学习机(ELM)方法、BP神经网络方法、RBF神经网络方法、支持向量机(SVM)方法.

表2表示实验中滚动轴承4类数据基于5种诊断方法的分类精度.

表2 5种诊断方法的分类准确度 %

类别	ELM	RBF	BP	SVM	O-DAG-LDM
IRF	99.80	98.40	97.40	99.60	99.80
BF	93.00	98.80	86.20	95.60	96.40
ORF	95.80	76.00	81.80	88.40	96.20
NR	86.40	93.20	85.80	96.60	95.60

从表2中可以看出,所提出的优化型DAG-LDM分类方法(O-DAG-LDM)对于每一类的分类准确度都在95%之上,且收敛结果比较稳定,表明O-DAG-LDM具有更好的准确性.

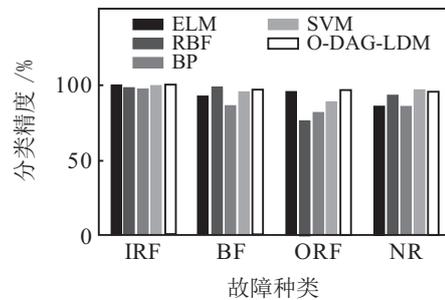


图5 4类数据的5种诊断方法分类准确度

为了更加直观地比较分类效果,对表2实验结果数据进行可视化,如图6所示,此图为实验中所用到的5种故障诊断方式对于4种不同测试数据的分类结果图,其中图6(a)表示BP神经网络分类示意图,图6(b)表示RBF神经网络分类示意图,图6(c)表示极限机分类示意图,图6(d)表示传统支持向量机分类示意图,图6(e)表示本文用到的O-DAG-LDM分类示意图.

由于数据具有高维度和非线性特点,便于实验分析,在实验中利用t-SNE降维方法将数据降维成2维图.从图6中可以清楚看出,O-DAG-LDM方法与其他方法相比,4种分类数据重叠更少、边界更加明显,说明所分同类数据相似性更高,可以得出在轴承故障

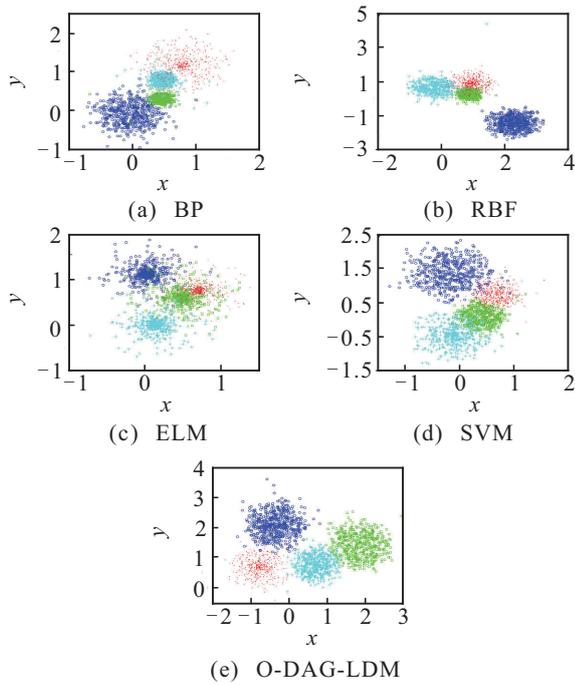


图6 5种故障诊断方式对4种不同数据的分类结果

诊断方面本文方法具有更好的诊断效果. 在滚动轴承4种类型的分类问题上, 可以从图5中直观得出, O-DAG-LDM明显优于ELM、BP算法, 这是因为ELM单层极限学习机与BP神经网络对非平稳原始信号的分类效果不佳. O-DAG-LDM与RBF相比, O-DAG-LDM在第2类球体(BF)故障诊断率上稍逊色, 在其他3类数据分类结果上O-DAG-LDM表现较好; 在IRF、BF和ORF三类故障分类结果上, O-DAG-LDM性能优于SVM性能, 这是因为O-DAG-LDM考虑了分类结构的优化排列, 同时基于间隔分布正则化的大间隔分布机(LDM)通过最大化间隔分布, 优化了间隔均值和间隔方差, 增强了模型的泛化性能, 从而取得了较强的抗噪性能及优于SVM等先进方法的分类性能. 值得注意的是, 从故障类型上看, 其他4种方法对于球体故障和正常数据分类效果并不是特别理想, 在前面的数据特性中已经提出, 球体故障数据和正常数据都在某些特有频率上没有固定的振动周期, 两种自相似性较低给分类带来了一些难度, 但是O-DAG-LDM的整体性能更好, 是因为它既考虑了分类结构的优先顺序, 同时也优化了平均间隔和间隔方差, 提高了模型分类精度.

表3显示了运用BP、RBF、ELM、SVM和O-DAG-LDM对4类数据分类的平均准确度.

表3 4类数据分类的5种算法平均准确度 %

分类算法	BP	RBF	ELM	SVM	O-DAG-LDM
平均准确度	87.80	91.60	93.75	95.05	97.00

图7显示了5种算法对4种故障分类的平均准确度.

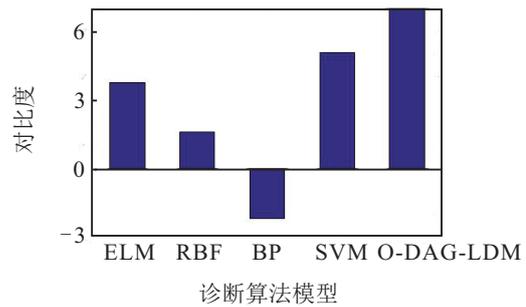


图7 5种算法的平均分类精度对比

从表3中统计数据可以看出, O-DAG-LDM的平均准确度最高为97%(图7中0代表90%的准确度为基础参照, 基础参照以上为递增, 基础参照以下为递减), 其次为SVM、ELM、RBF、BP, 进一步说明所提出的基于O-DAG-LDM的故障分类方法优于其他算法, 有着较高的平均准确度, 同时说明所提出的方法O-DAG-LDM具有很好的鲁棒性. 以上实验结果说明, 本文算法O-DAG-LDM非常适合滚动轴承非线性非平稳信号的故障诊断.

为了能够进一步验证所提出的方法的轴承故障诊断效果, 将本文的诊断方法与现有经典方法进行对比, 结果如表4所示.

表4 不同故障诊断方法性能比较

文献	故障诊断方法	平均准确率/%
[21]	MF-DFA+POS+LLSVM	94.276
[22]	CNDAG-SVM	91.50
[23]	小波包+shannon熵+SVM	96.84
[24]	MPE+ANFC	92.50
本文	O-DAG-LDM	97.00

实验结果表明, 与现有的轴承故障诊断方法相比, 本文提出的故障诊断有更高的故障识别率.

4 结论

节点优化型有向无环图大间隔分布机(O-DAG-LDM)可以有效地进行滚动轴承故障诊断. 所提出的优化型DAG结构扩展式LDM多分类器方法有机融合了DAG多分类扩展性能与LDM二分类器泛化性能的优势, 通过利用DAG结构将高效二分类器LDM扩展成多分类器来进行故障诊断. 通过对DAG节点的优化组合有效提高了数据划分精度, 降低了大间隔分布机(LDM)错误划分概率. 实验表明, 与其他主流智能诊断方法相比, 本文提的节点优化型DAG-LDM故障诊断方法具有较高的准确率和更好的抗噪性能, 对提高机组滚动轴承安全运行具有一定的价值. 然而, DAG结构排列不是唯一的, 不同的DAG结构对应

不同的DAG-LDM多分类器性能.在不增加时间和空间开销的情况下,研究新的DAG节点组合优化方法,进一步提升DAG-LDM多分类器对非线性非平稳信号智能分类性能将是接下来的研究方向.

参考文献(References)

- [1] Feng Z, Liang M. Complex signal analysis for wind turbine planetary gearbox fault diagnosis via iterative atomic decomposition thresholding[J]. *J of Sound & Vibration*, 2014, 333(20): 5196-5211.
- [2] Zheng H, Zhou L. Rolling element bearing fault diagnosis based on support vector machine[C]. *Int Conf on Consumer Electronics, Communications and Networks*. Yichang: IEEE, 2012: 544-547.
- [3] Wang D, Zhao Y, Yi C, et al. Sparsity guided empirical wavelet transform for fault diagnosis of rolling element bearings[J]. *Mechanical Systems & Signal Processing*, 2018, 101: 292-308.
- [4] Gao H, Liang L, Chen X, et al. Feature extraction and recognition for rolling element bearing fault utilizing short-time fourier transform and non-negative matrix factorization[J]. *Chinese J of Mechanical Engineering*, 2015, 28(1): 96-105.
- [5] He M, He D. Deep learning based approach for bearing fault diagnosis[J]. *IEEE Trans on Industry Applications*, 2017, 53(3): 3057-3065.
- [6] Wei X C, Tang Y L, Chen T. Research of rolling bearing fault feature extraction based on EMD and choi-williams[J]. *Advanced Materials Research*, 2013, 694-697: 1377-1381.
- [7] 康守强, 王玉静, 姜义成, 等. 基于超球球心间距多类支持向量机的滚动轴承故障分类[J]. *中国电机工程学报*, 2014, 34(14): 2319-2325.
(Kang S Q, Wang Y J, Jiang Y C, et al. Rolling bearing fault classification based on multi-ball spherical distance multi-support vector machine[J]. *J of China Electromechanical Engineering*, 2014, 34(14): 2319-2325.)
- [8] Li J, Li M, Zhang J. Rolling bearing fault diagnosis based on time-delayed feedback monostable stochastic resonance and adaptive minimum entropy deconvolution[J]. *J of Sound & Vibration*, 2017, 401: 139-151.
- [9] Zheng J, Pan H, Cheng J. Rolling bearing fault detection and diagnosis based on composite multiscale fuzzy entropy and ensemble support vector machines[J]. *Mechanical Systems & Signal Processing*, 2017, 85: 746-759.
- [10] Laha S K. Enhancement of fault diagnosis of rolling element bearing using maximum kurtosis fast nonlocal means denoising[J]. *Measurement*, 2017, 100: 157-163.
- [11] Shao H, Jiang H, Zhang H, et al. Electric locomotive bearing fault diagnosis using novel convolutional deep belief network[J]. *IEEE Trans on Industrial Electronics*, 2018, 65(3): 2727-2736.
- [12] Chen Z, Deng S, Chen X, et al. Deep neural networks-based rolling bearing fault diagnosis[J]. *Microelectronics Reliability*, 2017, 75: 327-333.
- [13] An X, Zeng H, Li C. Demodulation analysis based on adaptive local iterative filtering for bearing fault diagnosis[J]. *Measurement*, 2016, 94: 554-560.
- [14] Zhou Z H. Large margin distribution learning[C]. *Proc of the 6th IAPR TC3 Int Workshop*. Cham: Springer International Publishing, 2014: 1-10.
- [15] Wen C H, Zhang J, Cheng F Y. Handwritten music symbol classification based on DAG-LDM[J]. *J of Electronic Measurement and Instrumentation, Instrumentation*, 2016, 30(5): 764-771.
- [16] Platt J C, Cristianini N, Shawe-Taylor J. Large margin DAG s for multiclass classification[C]. *Proc of Neural Information Processing Systems*. Massachusetts: MIT Press, 2000: 547-553.
- [17] Vapnik V. The nature of statistical learning theory[M]. New York: Springer, 2000: 988-999.
- [18] Cotter A, Srebro N, Shalev-Shwartz S. Learning optimally sparse support vector machines[C]. *Int Conf on Machine Learning*. Atlanta: Springe, 2013: 266-274.
- [19] 易辉, 宋晓峰, 姜斌, 等. 基于结点优化的决策导向无环图支持向量机及其在故障诊断中的应用[J]. *自动化学报*, 2010, 36(3): 427-432.
(Yi H, Song X F, Jiang B, et al. Support vector machine based on nodes refined decision directed acyclic graph and its application to fault diagnosis[J]. *Acta Automatica Sinica*, 2010, 36(3): 427-432.)
- [20] Loparo K. Case western reserve university bearing data center[M/OL]. <http://csegroupscase.edu/bearingdatacenter/>.
- [21] 熊庆, 张卫华. 基于MF-DFA与PSO优化LSSVM的滚动轴承故障诊断方法[J]. *振动与冲击*, 2015, 34(11): 188-193.
(Xiong Q, Zhang W H. Fault diagnosis of rolling bearings based on LS-FVM and PSO optimization of LSSVM[J]. *J of Vibration and Shock*, 2015, 34(11): 188-193.)
- [22] 石瑞敏, 杨兆建. 基于复杂网络优化的 DAG-SVM在滚动轴承故障诊断中的应用[J]. *振动与冲击*, 2015, 34(12): 1-6.
(Shi R M, Yang Z J. Application of DAG-SVM in fault diagnosis of rolling bearing based on complex network optimization[J]. *J of Vibration and Shock*, 2015, 34(12): 1-6.)
- [23] 张亚楠, 魏武, 武林林. 基于小波包Shannon熵SVM和遗传算法的电机机械故障诊断[J]. *电力自动化设备*, 2010, 30(1): 87-91.
(Zhang Y N, Wei W, Wu L L. Fault diagnosis of electrical machinery based on wavelet packet shannon entropy SVM and genetic algorithm[J]. *Electric Power Automation Equipment*, 2010, 30(1): 87-91.)
- [24] Tiwari R, Gupta V K, Kankar P K. Bearing fault diagnosis based on multi-scale permutation entropy and adaptive neuro fuzzy classifier[J]. *J of Vibration & Control*, 2015, 21(3): 461-467.

作者简介

刘朝华(1983—), 男, 副教授, 博士, 从事人工智能与机器学习、新能源装备状态监测与智能故障诊断技术等研究, E-mail: zhaohualiu2009@hotmail.com;

孟旭东(1992—), 男, 硕士生, 从事机器学习与智能故障诊断的研究, E-mail: 1337721766@qq.com;

陆碧良(1995—), 男, 硕士生, 从事机器学习与智能故障诊断的研究, E-mail: 1197393632@qq.com;

李小花(1984—), 女, 讲师, 硕士, 从事机器学习与智能故障诊断的研究, E-mail: lixiaohua_0227@163.com;

童成意(1965—), 男, 教授, 从事机器学习与故障诊断等研究, E-mail: 329699077@qq.com.