



(12)发明专利申请

(10)申请公布号 CN 106980822 A

(43)申请公布日 2017.07.25

(21)申请号 201710148872.6

(22)申请日 2017.03.14

(71)申请人 北京航空航天大学

地址 100191 北京市海淀区学院路37号北
京航空航天大学

(72)发明人 吕琛 王振亚 马剑 周博

(74)专利代理机构 北京元本知识产权代理事务
所 11308

代理人 秦力军

(51)Int.Cl.

G06K 9/00(2006.01)

G06K 9/62(2006.01)

G06N 3/08(2006.01)

G06F 17/14(2006.01)


权利要求书2页 说明书14页 附图8页

(54)发明名称

一种基于选择性集成学习的旋转机械故障
诊断方法

(57)摘要

本发明公开了一种基于选择性集成学习的
旋转机械故障诊断方法,包括:对已知输入信号
进行预处理,得到训练序列;利用Bagging算法对
所述训练序列进行处理,生成一系列差异化的基
学习机;通过选择性集成学习,对所述一系列差
异化的基学习机进行优选,得到训练好的PSOSEN
模型;利用训练好的PSOSEN模型进行旋转机械故
障诊断。本发明解决了现有技术中存在的难于从
一系列分类器中选出性能较好的分类器的难题。



1. 一种基于选择性集成学习的旋转机械故障诊断方法,包括:
对已知输入信号进行预处理,得到训练序列;
利用Bagging算法对所述训练序列进行处理,生成一系列差异化的基学习机;
通过选择性集成学习PSOSEN,从所述一系列差异化的基学习机中得到训练好的PSOSEN模型;
利用训练好的PSOSEN模型进行旋转机械故障诊断。
2. 根据权利要求1所述的方法,其中,所述的对已知输入信号进行预处理得到训练序列和测试序列包括:
获取不同故障状态下的特征向量,考虑到故障诊断的实际需求,该特征向量通常指监测数据的时频域特征,如均方根、小波能量系数和熵等,从而得到训练序列。
3. 根据权利要求1所述的方法,其中,所述的利用Bagging算法对所述训练序列进行处理,生成一系列差异化的基学习机包括:
利用基于Bootstrap思想的Bagging对所述训练序列进行重构,生成基学习机PNN网络序列,即一系列差异化的基学习机;
对所述一系列差异化的基学习机的权重序列进行初始化。
4. 根据权利要求3所述的方法,其中,所述的利用基于Bootstrap思想的Bagging对所述训练序列进行重构,生成基学习机PNN网络序列包括:
通过Bagging过程,从原始训练数据中生成一个部分重合的序列,用于训练不同的个体PNN网络,进而提高基分类器集合对学习对象的表达能力。
5. 根据权利要求1所述的方法,其中,所述的通过选择性集成学习,从所述一系列差异化的基学习机中得到训练好的PSOSEN模型包括:
在差异化的基学习机生成过程结束后,利用改进的优化算法APS0,根据诊断适应度需求,不断对PNN网络序列的权重向量进行寻优,得到PNN网络的最终权重分布 D_t ;
根据所述最终权重分布 D_t ,从所述PNN网络序列中得到训练好的PSOSEN模型。
6. 根据权利要求5所述的方法,其中,所述的根据最终权重分布 D_t 得到训练好的PSOSEN模型。包括:
根据所述最终权重分布 D_t ,选出最终的多个PNN网络;
对所述最终的多个PNN网络的全局最优矩阵进行SVD分解,确定所述最终的多个PNN网络所对应的最优权向量参数,从而得到训练好的PSOSEN模型。
7. 根据权利要求6所述的方法,其中,所述的根据所述最终权重分布 D_t ,选出最终的多个PNN网络包括:
将所述最终权重分布 D_t 与预定的阈值进行比较,得到大于阈值的最终权重;
将所述PNN网络序列中其最终权重大于阈值的多个PNN网络选作所述最终的多个PNN网络。
8. 根据权利要求5所述的方法,其中,所述改进的优化算法APS0是引入衰减速度因子和聚合度因子的优化算法PSO。
9. 根据权利要求8所述的方法,其中,利用所述衰减速度因子和聚合度因子对所述PSO的初始惯性权重进行调节,得到非线性动态惯性递减权重。
10. 根据权利要求9所述的方法,其中,在所述PNN网络序列的权重向量进行寻优过程

中,利用所述非线性动态惯性递减权重自适应地调整搜索空间区域的大小,避免因聚合程度过高而陷入局部最优化的过拟合情况。

一种基于选择性集成学习的旋转机械故障诊断方法

技术领域

[0001] 本发明涉及旋转机械故障诊断领域,特别涉及一种基于自适应粒子群优化的选择性集成学习(particle swarm optimization based selective ensemble learning, PSOSEN)的旋转机械故障模式识别方法及装置。

背景技术

[0002] 故障诊断技术是随着现代工业大生产的发展而兴起的一项设备诊断技术,其旨在设备运行中或停机时基本不拆卸的情况下,通过信号处理、模式识别等方法,掌握设备的运行现状,判定设备故障的部位、原因、严重程度和状态,进而实现设备寿命和可靠性的预测,为维修决策的制定提供有效参考。近年来,以轴承、齿轮箱、泵类为代表的旋转机械故障诊断技术研究在学术界和工业界得到了愈发广泛的关注。

[0003] 旋转机械作为机电系统中的重要组成部分,其工作状态对整个系统的稳定可靠运行具有巨大的影响。由于高转速和复杂工况的影响,旋转机械的故障诊断问题一直是机电产品旋转机械健康维护的一个重要研究方向。其中,旋转机械的故障诊断通常可以包括特征提取和故障模式识别两个部分。特征提取的目的是利用时域和频域分析等方法,从监测信号中得到能够有效表达当前轴承故障状态的参量,例如时域指标均方根、翘度和频域指标小波系数等,这些参量作为轴承故障的特征,是故障模式识别的基础。故障模式识别的目的是基于提取的特征数据,利用有效的分类器,准确定位旋转机械中发生故障的组成部件,为维护维修与可靠性设计做出评判依据。

[0004] 随着机电产品经济性、可靠性和安全性要求不断提高,近年来为了满足操作者在健康管理与维护方面的需求,逐渐发展出一系列相关的特征提取和故障诊断方法。在特征选择方面,现有技术主要集中在时域和频域分析领域,通过统计数学或频域分析方法,提取出能够表征故障特性的信号指标,典型方法如经验模态分解(EMD)和小波分析等。EMD能够将任何复杂信号分解为几个基本模态分量(IMF)的叠加,进而通过希尔伯特黄变换得到瞬时幅值和瞬时频率,较适合时变信号。小波分析是傅里叶变换的拓展,可以将信号整合为一系列小波的组合,从频域角度提取到信号的有用特征。此外,随着信息传感技术的发展,还出现了众多适用于不同对象的衍生分析方法。如局部特征尺度分解(LMD)、压缩感知(CS)等,并产生了在特征提取基础上的特征优化和降维方法,典型例子如主成分分析(PCA)和平均影响值评估(MIV)等。在故障模式识别方面,已有神经网络、支持向量机(SVM)等众多方法,这些方法利用提取出的特征,训练得到合理的模型参数,通过识别旋转机械部件不同故障状态的差异性,提取得到对应的故障类别标签,实现故障判别。

[0005] 考虑到故障诊断的需求,集成学习由于其在泛化能力上的显著优势,在近年来的模式识别领域得到了迅速的推广,并在小样本、高维度和复杂数据结构对象上取得了良好的应用效果。与传统的“分而治之”的异构集成理念不同,集成学习可以通过数据重构,训练得到差异化的基学习机,再通过某种融合策略,强化对同一个数据集的模式识别能力。与个体算法相比,集成学习技术可以通过模型集成和误差平均,提高分类的泛化能力,降低过拟

合的风险,其已在图像识别、医疗诊断、生物基因检测等领域取得了广泛的应用。然而,在集成学习中,研究发现基分类器数目过多,其中性能较差的分类器反而有可能会导致分类的精确度下降,并消耗不必要的存储资源。因此,研究人员提出了选择性集成学习的思想,即通过优化、聚类或排序等手段,从构建的基学习机中选择出性能较好的分类器,代替全体集成。选择性集成学习的一个优势就在于能够通过只集成性能较好的学习机,以更小的资源消耗强化诊断的精度和效率。

发明内容

[0006] 为了解决现有技术存在的旋转机械数据的复杂性的问题,本发明提出了一种基于选择性集成学习的旋转机械故障诊断方法。

[0007] 本发明的基于选择性集成学习的旋转机械故障诊断方法包括:

[0008] 对已知输入信号进行预处理,得到训练序列;

[0009] 利用Bagging算法对所述训练序列进行处理,生成一系列差异化的基学习机;

[0010] 通过选择性集成学习PSOSEN,从所述一系列差异化的基学习机中得到训练好的PSOSEN模型;

[0011] 利用训练好的PSOSEN模型进行旋转机械故障诊断。

[0012] 其中,所述的对已知输入信号进行预处理得到训练序列和测试序列包括:

[0013] 获取不同故障状态下的特征向量,考虑到故障诊断的实际需求,该特征向量通常指监测数据的时频域特征,如均方根、小波能量系数和熵等,从而得到训练序列。

[0014] 其中,所述的利用Bagging算法对所述训练序列进行处理,生成一系列差异化的基学习机包括:

[0015] 利用基于Bootstrap思想的Bagging对所述训练序列进行重构,生成基学习机PNN网络序列,即一系列差异化的基学习机;

[0016] 对所述一系列差异化的基学习机的权重序列进行初始化。

[0017] 其中,所述的利用基于Bootstrap思想的Bagging对所述训练序列进行重构,生成基学习机PNN网络序列包括:

[0018] 通过Bagging过程,从原始训练数据中生成一个部分重合的序列,用于训练不同的个体PNN网络,进而提高基分类器集合对学习对象的表达能力。

[0019] 其中,所述的通过选择性集成学习,从所述一系列差异化的基学习机中得到训练好的PSOSEN模型包括:

[0020] 在差异化的基学习机生成过程结束后,利用改进的优化算法APSO,根据诊断适应度需求,不断对PNN网络序列的权重向量进行寻优,得到PNN网络的最终权重分布 D_t ;

[0021] 根据所述最终权重分布 D_t ,从所述PNN网络序列中得到训练好的PSOSEN模型。

[0022] 其中,所述的根据最终权重分布 D_t 得到训练好的PSOSEN模型。包括:

[0023] 根据所述最终权重分布 D_t ,选出最终的多个PNN网络;

[0024] 对所述最终的多个PNN网络的全局最优矩阵进行SVD分解,确定所述最终的多个PNN网络所对应的最优权向量参数,从而得到训练好的PSOSEN模型。

[0025] 其中,所述的根据所述最终权重分布 D_t ,选出最终的多个PNN网络包括:

[0026] 将所述最终权重分布 D_t 与预定的阈值进行比较,得到大于阈值的最终权重;

[0027] 将所述PNN网络序列中其最终权重大于阈值的多个PNN网络选作所述最终的多个PNN网络。

[0028] 其中,所述改进的优化算法APS0是引入衰减速度因子和聚合度因子的优化算法PS0。

[0029] 其中,利用所述衰减速度因子和聚合度因子对所述PS0的初始惯性权重进行调节,得到非线性动态惯性递减权重。

[0030] 其中,在所述PNN网络序列的权重向量进行寻优过程中,利用所述非线性动态惯性递减权重自适应地调整搜索空间区域的大小,避免因聚合程度过高而陷入局部最优化的过拟合情况。

[0031] 本发明的有益技术效果是,通过基于APS0的基分类器优选,从一系列分类器中选出性能更好的分类器,从而解决了现有技术的难题。

附图说明

[0032] 图1是PNN网络的基本结构图;

[0033] 图2是PSOSEN模型诊断流程图;

[0034] 图3是旋转作动器工作原理图;

[0035] 图4是RBF观测器原理图;

[0036] 图5是五种故障模式计算得到的残差示意图,其中(a)图表示正常,(b)图表示伺服阀故障,(c)图表示液压马达故障,(d)图表示旋转作动器故障,(e)图表示轴故障;

[0037] 图6是显示五种案例情况下的故障诊断结果的示意图;

[0038] 图7是PSOSEN和GASEN优化过程示意图;

[0039] 图8是本发明采用的液压泵试验台示意图;

[0040] 图9是显示不同诊断算法液压泵故障诊断结果的示意图;

[0041] 图10是显示不同SNRs下的信噪比分布的示意图;

[0042] 图11是本发明的基于选择性集成学习的旋转机械故障诊断方法的示意图。

具体实施方式

[0043] 1、基分类器的生成

[0044] 本发明采用概率神经网络 (probabilistic neural networks,PNN) 作为基分类器,实现旋转机械故障模式的识别。PNN是一种基于贝叶斯最小风险准则和核费希尔判别的前向神经网络,是D.F.Speccht在1990年发明的。通常情况下,PNN网络结构如图1所示。

[0045] 在图1中,我们可以发现PNN网络通常可以分为四层:即输入层、模式层、累加层和输出层。当给与该网络一个测试输入信号时,在输入层首先会计算信号中数据点和训练向量点之间的距离;然后,模式层会利用一个径向基函数,将距离转化为不同数据点所对应的权值参数;在叠加层,会将输入数据中各点针对不同故障模式的权值参数累加起来,并输出一个概率向量;输出层将概率向量转化为预期的标签形式,作为网络的最终输出结果。

[0046] 我们假设一个输入向量为 $X = (x_1, x_2, x_3, \dots, x_n)$,其包括两种故障模式 θ_A 和 θ_B ,则PNN网络的分类过程可以大致总结为:

[0047] 如果 $h_{A1}\theta_A(X) > h_{B1}\theta_B(X)$,则 $X \in \theta_A$;

[0048] 如果 $h_{\text{A}}(X) < h_{\text{B}}(X)$, 则 $X \in \theta_{\text{B}}$.

[0049] 其中 h_{A} 和 h_{B} 分别表示故障模式 θ_{A} 和 θ_{B} 的先验概率。假定 N_{A} 和 N_{B} 是在训练数据中, 训练样本分别属于 θ_{A} 和 θ_{B} 的数目, N 是训练样本的总数, 则 h_{A} 和 h_{B} 可以按照 $h_{\text{A}} = N_{\text{A}}/N$, $h_{\text{B}} = N_{\text{B}}/N$ 的方式进行计算。 l_{A} 是分类过程中的代价因子, 表示在训练集中, 属于故障模式 θ_{A} 的样本被错误分类到故障模式 θ_{B} 的比率, l_{B} 与之相反。 f_{A} 和 f_{B} 分别表示故障模式 θ_{A} 和 θ_{B} 的概率密度函数。

[0050] 根据以上理论, 我们可以发现PNN分类过程类似于一种利用RBF核函数来计算多变量下不同故障模式概率密度分布情况的贝叶斯分类方法, 以故障模式 θ_{A} 为例, 其对应的概率密度函数可以定义为:

$$[0051] F_{\text{A}}(X) = \frac{1}{(2\pi)^{p/2} \delta^p m} \sum \exp \left[-\frac{(X - X_{Aj})^T (X - X_{Aj})}{2\delta^2} \right] \quad (1)$$

[0052] 公式(1)中, X 为输入样本向量, s 为样本向量的变量个数。 X_{Aj} 为属 A 类的第 j 个训练样本向量, 在概率神经网络中作为权重, m 表示属于 A 类的训练样本向量个数, δ 为光滑系数。

2、选择性集成学习理论

[0054] 个体PNN网络大多依赖于比较好的训练输入特征来构建出适合于不同决策边界的映射关系, 这就使得其泛化能力很大程度上受限于人工特征提取和先验知识。为了进一步提高其泛化性能, 本发明引入集成学习的思想, 通过构建和集成差异化的个体PNN分类器, 提高旋转机械的故障诊断能力。在集成学习中, 很重要的一个原则就是差异性, 即不同的个体学习机之间应该相对独立, 进而从不同角度挖掘出数据中隐含的特征信息, 典型方法如 Boosting 和 Bagging 等, 然后通过加权投票等方式得到最终的预测结果。对旋转机械故障诊断来说, 本发明采用 Bagging 的方法来构建个体学习机, 通过有放回随机抽样的方式, 构建出包含不同特征信息的PNN模型。适用于诊断的集成学习框架可归纳为:

[0055] 对于一个从输入特征到故障模式的映射关系 $f: R^m \rightarrow D$, D 表示测试集的标签, 有 N 个参与集成的个体PNN网络。假定每个基学习机的学习误差率为 q , 则集成学习的整体泛化误差可以表示为:

$$[0056] Te = \sum_{k=[N/2]}^N q^k (1-q)^{(N-k)} \quad (2)$$

[0057] 如公式(2)所示, 当满足如下两个条件时, 集成学习可以有效提高诊断的泛化性能: (1) 学习误差率小于 50%; (2) 各基学习机之间相互独立。然而, 如果在集成学习中存在过多的基分类器, 有可能会使得无意义的计算和存储资源消耗过大。为了解决这个问题, 研究人员提出了选择性集成学习的概念, 即通过某种手段从生成的分类器中, 选择出性能较好的个体来构建最终集成, 从而在保证精度的情况下, 进一步提升泛化性能和计算效率。

[0058] 在故障诊断时, 令 f_{ij} 和 d_j 分别表示第 i 个PNN网络针对第 j 个特征向量的实际输出和预期输出。以三分类故障诊断为例, f_{ij} 和 d_j 的格式可以表征为 $\{1, 0, 0\}$, 其中 1 所处的位置代表旋转机械对应的故障模式类型。

[0059] 那么, 第 i 个PNN网络针对所有特征向量的泛化误差 p_i 可以定义为:

$$[0060] p_i = \frac{1}{m} \sum_{j=1}^m \text{Error}(f_{ij} * d_j) \quad (4)$$

[0061] 其中, m 表示特征的数量, $\text{Error}(x)$ 是一个示性函数:

[0062]
$$\text{Error}(x) = \begin{cases} 1 & \text{if } x=0; \\ 0 & \text{if } x=1; \end{cases}$$

(5)

[0063] 在此基础上,针对第j个特征向量,N个PNN网络的集成结果可以表示为:

[0064]
$$\text{sum}_j(x, w) = \sum_{i=1}^N \omega_i f_i(x) \quad (6)$$

[0065] ω_i 表示PNN集合的权重向量,在最常见的专家投票法中,可以认为每个权重均为 $1/N$ 。则针对整个数据集,集成学习的泛化误差可以定义为:

[0066]
$$p = \frac{1}{m} \sum_{j=1}^m \text{Error}(\text{sum}_j * d_j) \quad (7)$$

[0067] 进一步基于公式(6)和(7),我们可以给出考虑保证分类器泛化性能的前提下,选择性集成学习的条件为:

[0068]
$$\text{Error}((\text{sum}_j - \sum_{k=1}^l \omega_k f_k) * d_{j-k}) = 0 \quad (8)$$

[0069] 在公式(8)中, f_k 表示被剔除的性能不好的基学习机, ω_k 是这些学习机对应的权重, d_{j-k} 是余下学习机对应的标签向量。该公式表明,通过剔除部分学习性能不好的分类器,可以在不增大集成误差的前提下,进一步增强诊断性能和效率。

[0070] 3、基于APSO的基分类器优选

[0071] 虽然选择性集成学习比所有分类器集成具备更大的优势,但如何从分类器中选择出性能较好的分类器,依然是当前的一个难题。在实际问题中,人工挑选和先验知识等方法需要消耗大量的计算资源。然而,在旋转机械故障诊断中,由于每个PNN的输出是相同的,由公式(7)和公式(8)可得,基学习机的优选过程可以认为是一个以集成权重序列为对象的优化过程。因此,本发明提出了一种改进的优化算法(APSO)来自适应地评估每个基学习机的性能,并选出权重大于阈值的PNN集合,用于构建最终的集成诊断学习器。

[0072] 该算法是一种改进的粒子群寻优算法,借鉴了鸟类等群体在寻找食物中确定最佳路径的过程。这些粒子在一定区域内持续移动,根据适应度函数,确定在寻优过程中的个体最优位置和群体最优位置。在每次迭代过程中,粒子都会运动到一个新的位置,并将该位置作为下一次寻优的起点。粒子的适应度和速度会随着粒子性能评估不断更新。在本发明中,基本的APSO步骤如下:

[0073] 对于N个PNN网络,假定一个L维的搜索空间, $W = (W_1, W_2, \dots, W_N)$ 表示种群规模, W_i 是搜索空间中的第i个粒子,可定义为 $W_i = (\omega_{i1}, \omega_{i2}, \dots, \omega_{iL})^T$, $\{\omega_{ij}\}$ ($i=1:L, j=1:N$)表示待优化的集成权重向量。在诊断中的适应度函数可定义为:

[0074]
$$F = \min\left(\frac{p}{m}\right)$$

(9)

[0075] 其中,p和m分别表示步骤(2)中定义的诊断中的泛化误差和特征数目。F可以认为是在每次迭代中的个体最优位置Gbest,而全局最优位置Zbest是一个包含不断更新的个体最佳权重向量的矩阵。令第i个粒子的寻优速度为 $V_i = (v_{i1}, v_{i2}, \dots, v_{iL})^T$,在下次更新时的起始位置和速度可按照如下公式进行计算:

[0076] $v_{ij}^{t+1} = \theta v_{ij}^t + c_1 r_1 (Gbest_{ij}^t - \omega_{ij}^t) + c_2 r_2 (Zbest_{ij}^t - \omega_{ij}^t) \quad (10)$

[0077] $\omega_{ij}^{t+1} = \omega_{ij}^t + v_{ij}^{t+1} \quad (11)$

[0078] 其中, θ 是一个惯性权重, c_1 和 c_2 是调节 Gbest 和 Zbest 重要程度的加速因子, r_1 和 r_2 是 0-1 之间的一个随机常量。惯性权重 θ 是优化过程中的一个核心参数, 常通过线性递减策略来计算, 但往往会导致其容易陷入局部最优的情况。因此, 本发明提出了一种基于聚合关系的自适应寻优方法。

[0079] 定义 $F(Zbest^t)$ 为第 t 次迭代时的优化目标, 一个衰减速度因子 k_v 可定义为:

[0080] $k_v = \frac{\max(F(Zbest^t), F(Zbest^{t-1}))}{\min(F(Zbest^t), F(Zbest^{t-1}))} \quad (12)$

[0081] 一个聚合因子 k_a 可定义为:

[0082] $k_a = \frac{\max(|F(Zbest^t) - \bar{F}_t|)}{\min(|F(Zbest^t) - \bar{F}_t|)} \quad (13)$

[0083] 其中 \bar{F}_t 表示粒子的平均适应度量值。

[0084] 这样, 在 APSO 中我们提出了一种非线性动态惯性递减权重为:

[0085] $\theta(t)_{nonlinear} = \theta_{initial} - \omega_{kv}/k_v + \omega_{ka}/k_a \quad (14)$

[0086] 其中, $\theta_{initial}$ 是初始惯性权重, ω_{kv} 和 ω_{ka} 是用来 k_v 调节 k_a 重要程度的关联系数。通常情况下, k_v 越大, 权重递减速度越大, 而 k_a 越大, 粒子的聚合程度越低。在此基础上, 寻优过程可以根据收敛速度自适应地调整搜索空间区域的大小, 提高寻优效率, 同时避免因粒子聚集程度过高而陷入局部最优的过拟合情况。此外, ω_{kv} 和 ω_{ka} 可以根据优化需求动态调整, 使得 k_v 和 k_a 能够到达一个平衡点。

[0087] 当 APSO 寻优结束后, 可以选择出在 Zbest 中权重参量高于既定阈值 λ 的个体分类器, 用于构建最终的集成。也就是说, 权值越高, 对应的基分类器性能越好。在确定出基分类器子集后, 虽然对 Zbest 中的权重向量归一化, 可以得到集成权重向量, 但此方法只反映出了寻优过程中一种可能性, 在某种程度上容易损失一定有价值的信息。考虑到 Gbest 是所有迭代次数中最优权重向量的集合, 包含更为丰富的全局信息, 本发明通过对 Gbest 进行 SVD 分解处理, 得到更为适用的权重参数。

[0088] 假定从 N 个基分类器中选择出了 K 个 PNN 网络, $Gbest_{se}$ 是这 K 个分类器对应的全局最优矩阵 $L \times K$, 其中每一行表示 PNN 集合在该次迭代中对应的最优权重向量。我们对 $Gbest_{se}$ 进行 SVD 分解:

[0089] $Gbest_{se} = U \Lambda V^T \quad (15)$

[0090] 其中, Λ 表示奇异值矩阵。 U 和 V 分别是对应的左右正交矩阵。令 v_{max} 为在右正交阵中, 最大奇异值 s_{max} 对应的第一列特征向量。将 v_{max} 进行归一化, 可得到最终的集成权重为:

[0091] $\omega_{opti} : \left\{ \omega_{opti} = \frac{(v_{max})^2}{\sum_{i=1}^K (v_{max})^2} \right\} \quad i = 1 \dots K \quad (16)$

[0092] 相比于直接利用 Zbest, 此权重确定方法的优势在于可以通过最小化泛化误差, 使得分类概率最大程度地接近预期标签序列, 从而进一步提高旋转机械故障诊断的精度和鲁棒性。基于 APSO 选择性集成的结果输出为:

$$[0093] H_{DIW-PSO} = \arg \max_{\omega_{opt} \in (0,1)} \left(\sum_{i=1}^K \omega_{opt,i} * f_i(x) \right) \quad (17)$$

[0094] 4、基于选择性集成学习,本发明提出了一种旋转机械故障诊断方法,能够利用多个角度的特征参量,强化诊断的自适应能力和精确性。整个诊断流程如图2所示。

[0095] 参见图2,分类模型可以认为是从输入空间X到输出空间Y的一个映射,主要包括以下几个步骤:(1)获取不同故障状态下的特征向量。考虑到故障诊断的实际需求,该特征向量通常指监测数据的时频域特征,如均方根、小波能量系数和熵等;(2)产生差异化的个体学习机。基于Bootstrap思想的Bagging算法被用来初始化基分类器。Bootstrap是一种基于有放回随机重采样的数据生成方法,通过Bagging过程,会从原始训练数据 $X = (X_1, X_2, \dots, X_n)$ 中生成一个部分重合的序列 $X_b = (X_1^b, X_2^b, \dots, X_n^b)$ 用于训练不同的个体PNN网络,进而提高基分类器集合对学习对象的表达能力。每个生成分类器的权值按照近似平均的原则进行初始化。(3)选择出性能较好的PNN网络,并确定合理的权重向量。在预训练过程结束后,本发明利用APSO方法,根据诊断适应度需求,不断对权重向量进行寻优,得到最终的权重分布 D_t 。在APSO中,引入速度和聚合度因子来提高全局寻优能力。在每次迭代中, D_t 会持续更新,最终选择出其中权重大于既定阈值的分类器。之后,对全局最优矩阵进行SVD分解,确定参与集成的分类器所对应的最优权向量参数。(4)利用训练完成的PSOEN模型进行旋转机械故障诊断。

[0096] 5、案例研究

[0097] 旋转作动器和柱塞液压泵是旋转机械中的关键部件,由于复杂工作环境的影响,很容易产生多种类型的故障。因此,本发明以该两类对象为案例,验证所提出的PSOEN方法的有效性。

[0098] (1) 旋转作动器故障诊断

[0099] 1) 数据说明

[0100] 如图3所示,旋转作动器主要由一个负责根据反馈信号调整位移角的控制模块,一个PDU模块和一个行星轮系执行机构组成。PDU模块包括一个伺服阀、一个液压刹车机构、一个液压电机和一个功能转换阀。旋转可调差动变压器是一个用于电信号和角位移信号相互转化的角度位移传感器。在本实验中,共注入了五种故障模式:(1)正常状态;(2)驱动轴故障;(3)旋转作动器故障;(4)伺服阀故障;(5)液压电机故障。详细故障信息如下所示。

[0101] 故障故障模式信息

[0102]

故障模式	故障征兆	故障注入方式
正常	---	---
伺服阀故障	伺服阀泄漏	初始流量 $\times 0.7$
液压电机故障	电机泄露	泄漏系数被设定为 10^{-12}
旋转作动器故障	RVDT 精度降低	参数设定为 0.32
驱动轴故障	刚度降低	初始刚度 $\times 0.7$

[0103] 考虑到旋转作动器系统是一个非线性反馈控制系统,难以确定精确的数学模型,本发明根据RBF网络构建了如图4所示的一个故障观测器,用于获取系统真实输出和期望输

出之间的残差,从而通过残差量级更好地表征出不同故障状态对旋转作动器系统的影响。观测器模型结构和获得的残差如图5所示。

[0104] 2) 数据预处理

[0105] 时频域分析是目前最常用的信号处理方法,因此,本发明针对提出的残差信号提取相关的时频域特征,用于获取在数据波动和复杂工况下,对故障具有更好辨识性的特征量。本发明所提取的时域特征参数如下。

[0106] 表1时域统计特征

时域特征	公式	时域特征	公式
最大值	$X_{\max} = \max(x_i(t))$	均方根	$X_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$
标准差	$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2}$	翘度	$\beta = \frac{1}{N} \sum_{i=1}^N x_i^4$
均方根峰值	$X_r = \left(\sum_{i=1}^N \sqrt{ x_i } \right)^2$	峰峰值	$\max(x_i(t)) - \min(x_i(t))$

[0109] 小波变换是一种常用的在时频域领域内描述信号能量分布的特征表达方法,本发明提取小波能量、最大小波系数和小波熵作为故障特征指标,如下表所示。

[0110] 表2时频域统计特征

[0111]

时频域特征	Equations
小波能量	$E_{j,i} = \int_{-\infty}^{+\infty} x_j^i(t)^2 dt$
小波系数	$c_{j,k}^i = \int_{-\infty}^{+\infty} x(t) \psi_{j,k,i}(t) dt$
小波奇异熵	$W_j = - \sum_{m=1}^j \left[\left(\lambda_m / \sum_{l=1}^s \lambda_l \right) \log \left(\lambda_m / \sum_{l=1}^s \lambda_l \right) \right]$

[0112] 在表中,j表示小波分解的层数,i表示该层信号分解的顺序,k是位置标签,s是SVD分解得到的诊断矩阵的维数。

[0113] 为了验证所提出方法的泛化能力,不同比例的训练和测试数据从特征集中被分离出来,如表4所示。此外,为了更好地评价优化过程中个体的性能,本发明通过对训练集进行Bootstrap采样的方式得到一个验证集。训练集是为了初始训练PNN网络,验证集则是用于后期选择基分类器的优化过程。

[0114] 表3旋转作动器故障诊断:五种诊断案例

[0115]

案例	训练数据集 (%)	测试数据集 (%)
C1	10	90
C2	30	70
C3	50	50
C4	70	30
C5	90	10

[0116] 3) 基于PSOSEN的旋转作动器系统故障诊断

[0117] 在PSOSEN中,我们初始化20个PNN基分类器,每个分类器的训练子集重采样比例为80%。设定分类标签为二进制形式,即 $(1,0,0,0,0)$, $(0,1,0,0,0)$, $(0,0,1,0,0)$, $(0,0,0,1,0)$ 和 $(0,0,0,0,1)$ 分别对应正常、伺服阀故障、液压马达故障、作动筒故障和驱动轴故障。

[0118] 在基分类器选择阶段,设定最大和最小搜索速度为+1和-1,粒子大小为0-1,种群规模为100,迭代次数为50,递减速度和聚合度因子的相对权重分别为0.7和0.3。每次迭代中都对全局最优位置Gbest和个体最优位置Zbest进行更新。PSOSEN模型的详细参数如下表所示。

[0119] 表4旋转作动器诊断PSOSEN模型参数

[0120]

结构参数	PNN 基分类器个数	个体训练样本比例	数据重构方法	寻优方法	故障模式数目
	20	80%	Bagging	APSO	5
学习参数	寻优速度	粒子大小	种群规模	递减速度因子	聚合度因子
	1/-1	0-1	100	0.7	0.3

[0121] 在本案例中,我们设定选择阈值为0.2,即选出优化后权值高于0.2的基分类器用于构建最终的集成。对得到的全局最优矩阵进行SVD分解,取右正交阵中最大奇异值对应的特征向量为集成权重。基分类器权值优化过程如下表所示。

[0122] 表5案例1:PSOSEN权重更新过程

[0123]

ω_1	ω_2	ω_3	ω_4	ω_5	ω_6	ω_7	ω_8	ω_9	ω_{10}
ω_{11}	ω_{12}	ω_{13}	ω_{14}	ω_{15}	ω_{16}	ω_{17}	ω_{18}	ω_{19}	ω_{20}
Step 1: 随机初始化权重									
0.069	0.031	0.054	0.011	0.055	0.059	0.054	0.085	0.058	0.031
1	8	1	7	0	5	3	3	0	8
0.002	0.061	0.056	0.043	0.059	0.083	0.037	0.073	0.044	0.027
2	7	0	7	5	4	1	8	5	7
Step 2: 基于 APSO 的权值寻优									
0	0.446	0.075	0.360	0.129	0.051	0	0.160	0.442	0.595
	1	7	4	2	1		7	3	9
0.654	0.154	0.095	0.511	0	0.612	0.676	0.513	0.044	0.007
0	2	4	3		6	8	8	5	7
Step 3: PNN 优选和集成权重向量确定									
ω_2	ω_4	ω_9	ω_{10}	ω_{11}	ω_{14}	ω_{16}	ω_{17}	ω_{18}	
0.1599	0.0534	0.0644	0.0754	0.1598	0.1608	0.0267	0.1614	0.1382	

[0124] 本发明将PSOSEN模型与其它方法进行了对比。对比方法包括采用遗传算法的选择性集成学习模型GASEN,基于Boosting集成的多分类算法AdaBoost.M1,Bagging集成算法和个体模型PNN与SVM。在诊断中采用了十倍交叉验证方法,以计算出的诊断精度平均值和标准差作为衡量指标。泛化误差按照如下公式进行计算:

$$[0125] E = \frac{\sum_{i=1}^N \text{Error}(x_i)}{N} \quad (18)$$

[0126] 其中N表示输入样本的数目。Error (x_i) 是公式 (5) 中定义的示性函数。不同训练和测试比例下,每个算法的训练和测试精度如图6所示。

[0127] 表6Case 1诊断结果

[0128]

Methods	精度 (%)									
	C1		C2		C3		C4		C5	
	Mea	Std	Mean	Std	Mean	Std	Mean	Std	Mean	Std
n										
PSOSEN	91.82	2.44	93.40	1.42	93.56	1.46	94.75	1.23	95.11	0.72
GASEN	89.22	2.83	90.14	1.86	91.00	1.09	93.25	1.61	94.21	1.48
Bagging	83.36	2.54	86.90	1.39	89.02	1.96	92.33	2.13	94.01	1.89
Adaboost.M	88.87	3.03	89.75	2.34	92.99	1.62	93.94	1.66	95.55	1.89
1										
PNN	80.90	3.01	83.81	2.77	86.04	2.59	90.93	1.55	90.60	2.11
SVM	83.76	2.71	85.01	2.07	87.21	2.12	91.09	1.89	91.47	1.65

[0129] 从诊断结果中可以看出,从C1到C5,随着训练数据比例的提升,诊断的精度也随之增加。与个体PNN和SVM分类器相比,集成学习算法通过多角度学习强化了对样本数据的表达能力,并消除了训练过程中可能的负面影响,从而在大多数情况下都具备较高的分类精

度。以C3为例,PSOSEN、PNN、Bagging、AdaBoost.M1、GASEN和SVM的分类精度分别为93.56%、86.04%、89.02%、92.99%、91.00%和87.21%。此外,集成学习方法比个体方法具有更小的标准差,

[0130] 也就是在诊断中具备更高的鲁棒性。

[0131] 在集成学习类方法中,随着训练数据增加,集成学习类方法在C5时具有最高的诊断精度95.55%。此类Boosting算法的优势在于可以根据级联规则,调整基分类器对分类倾向的权重,进而提高诊断性能,降低过拟合风险。然而,相对于PSOSEN模型,AdaBoost.M1的标准差波动较大,诊断性能不够稳定。此外,PSOSEN和GASEN模型通过剔除性能不好的基分类器,具备比Bagging更好的诊断能力。在本发明中,APS0方法可以弥补遗传算法在高维数据中容易早熟的问题,以C2和C4为例,算法的优化过程如图7所示。

[0132] 参见图7,在相同的迭代次数中,APS0方法具备更好的收敛速度和全局搜索能力。例如,在C2时,训练数据较少,APS0可以比GA更快地收敛到更好的适应度范围。在C4中,虽然GA刚开始寻优效果较好,但随着迭代次数增加,其陷入了局部最优的情况,适应度的参数不再发生变化,而APS0则表现出了一个更为持续和稳定的寻优过程。

[0133] (2) 液压泵故障诊断

[0134] 1) 案例描述

[0135] 本案例中所采用的液压泵试验台如图8所示。该试验台主要包括一个柱塞泵,一个液压油路和一个驱动电机。电机转速为5280r/min。加速度传感器安装在端面处,用来收集振动信号数据,采样频率为1024Hz。

[0136] 实验中共注入了三种故障模式,包括正常、斜盘磨损和配流盘转子磨损,分别定义为故障模式S1,S2和S3。

[0137] 2) 数据预处理

[0138] 在本实验中,我们采用EMD分解和信息熵结合的方法来提取数据特征。首先,原始信号被分解为一系列本征模态分量(IMFs),然后计算这些IMFs的信息熵,作为PSOSEN诊断模型的输入。数据处理的基本流程如表8所示。

[0139] 表7液压泵数据预处理流程

[0140]

Step	按照滑移取点的方法, 将加速度信号分解为包含 300 个点的独立区域
1:	集合
Step	对每个区域进行 EMD 分解, 得到对应的 IMFs
2:	
Step	计算每一个 IMF 的 IE
3:	
Step	根据不同的健康状态, 对得到的 IEs 进行分类
4:	
Step	从 IE 特征中分离出训练和测试数据集
5:	

[0141] 对每一组IMFs,选取前八个IE来构造特征矩阵,也就是说,特征集中共包含300个样本,每个样本共包括8个IE分量。80%的特征量被随机选择作为训练集,20%作为测试集,对液压泵数据采用十倍交叉验证的方法来得到最终的诊断结果。

[0142] 3) 基于PSOSEN的液压泵故障诊断

[0143] 与旋转作动器系统诊断类似,设定集成PNN网络数目为20,bagging样本重构比例为80%,粒子大小为0-1,种群规模为100,迭代次数为100,初始的递减速度和聚合度因子分别为0.5和0.5,正常、斜盘磨损和配流盘转子磨损的故障标签分别为(1,0,0),(0,1,0)和(0,0,1)。模型详细参数信息如下表所示:

[0144] 表8 PSOSE模型参数

[0145]

结构参数	PNN基分类器个数	个体训练样本比例	数据重构方法	寻优方法	故障模式数目
	20	80%	Bagging	APSO	3
学习参数	寻优速度	粒子大小	种群规模	递减速度因子	聚合度因子
		小	模	子	子
	1/-1	0-1	100	0.5	0.5
					100

[0146] 在集成计算的三个步骤中,集成权重的更新过程如下表所示。

[0147] 表9案例2:PSOSEN权值更新

[0148]

ω_1	ω_2	ω_3	ω_4	ω_5	ω_6	ω_7	ω_8	ω_9	ω_{10}
ω_{11}	ω_{12}	ω_{13}	ω_{14}	ω_{15}	ω_{16}	ω_{17}	ω_{18}	ω_{19}	ω_{20}
Step 1: 随机初始化权重									
0.008 7 0.051 3	0.089 4 0.056 1	0.074 4 0.058 6	0.060 2 0.013 2	0.047 9 0.054 9	0.058 3 0.021 7	0.046 7 0.066 1	0.051 2 0.048 8	0.038 1 0.064 4	0.045 6 0.044 5
Step 2: 基于 APSO 的权值寻优									
0 9 0.252 3	0.102 1 0.407 7	0.004 7 0.008 2	0 0 0.135 6	0 7 0 6	0.289 4 0.094 6	0.643 7 0.112 6	0.000 7 0.112 1	0 9 0.009 1	0.078 9 0 0
Step 3: PNN 优选和集成权重向量确定									
ω_6		ω_{11}		ω_{12}		ω_{16}			
0.1181		0.1988		0.2473		0.4358			

[0149] 同理,我们将PSOSEN模型与案例1中的其它模型进行对比分析。每个模型的液压泵诊断结果如图9所示。

[0150] 在图中,红色表示预期的标签向量,蓝色表示实际分类得到的标签向量。可以观察到,虽然通过最优化训练,每个模型的精度都在90%以上,但集成学习模型比PNN具有更高的诊断精度,例如,PSOSEN模型分类正确率达到了100%,证明了其通过高效集成获取非线性故障特性的能力。值得注意的是,由于在小样本问题上的优越性,SVM方法取得了与集成学习在液压泵诊断数据集上相似的诊断性能。

[0151] 此外,考虑到液压泵通常工作在噪声较大的环境中,容易受到未知因素的影响,从而降低诊断精度。本发明在基础液压泵数据中进行了噪声压力测试,来验证PSOSEN方法的

噪声影响下的鲁棒性和泛化性能。我们将10dB、30dB和50dB的噪声添加至原有数据集中,用PCA的方法,将数据映射到一个二维空间内,如图10所示。

[0152] 在图中可以看出,随着噪声增加,不同故障模式的数据混淆程度也逐渐增大,证明了噪声确实会对分类任务带来不可忽视的影响,也要求诊断算法对数据具有更高的鲁棒性。所有模型的诊断结果如下表所示。

[0153] 表10不同SNRs下的诊断结果

[0154]

Method	Accuracy (%)					
	SNR: 10		SNR: 30		SNR: 50	
	Mean	Std	Mean	Std	Mean	Std
PNN	84.67	4.67	88.33	3.12	92.03	2.96
Bagging	86.43	3.24	92.83	2.89	95.50	2.14
Adaboost.M1	85.26	3.64	90.91	3.37	96.42	1.92
PSOSEN	91.86	1.67	96.76	1.87	99.03	1.01
GASEN	90.67	1.98	93.33	2.02	98.43	1.44
SVM	86.84	2.78	90.04	2.43	95.82	1.79

[0155] 从诊断结果中可以看出,虽然有噪声的影响,PSOSEN模型通过降低偏差和方差的影响,并凭借更好的优化过程来提高液压泵健康状态识别能力,取得了比其它模型更好的分类效果。例如,在信噪比较低为SNR10dB时,PSOSEN模型依然可以得到91.86%的分类正确率,证明了该模型能够更好地处理噪声带了的负面影响。

[0156] 综上所述,如图11所示,本发明的基于选择性集成学习的旋转机械故障诊断方法包括:

[0157] 对已知输入信号进行预处理,得到训练序列;

[0158] 利用Bagging算法对所述训练序列进行处理,生成一系列差异化的基学习机;

[0159] 通过选择性集成学习PSOSEN,从所述一系列差异化的基学习机中得到训练好的PSOSEN模型;

[0160] 利用训练好的PSOSEN模型进行旋转机械故障诊断。

[0161] 其中,所述的对已知输入信号进行预处理得到训练序列和测试序列包括:

[0162] 获取不同故障状态下的特征向量,考虑到故障诊断的实际需求,该特征向量通常指监测数据的时频域特征,如均方根、小波能量系数和熵等,从而得到训练序列。

[0163] 其中,所述的利用Bagging算法对所述训练序列进行处理,生成一系列差异化的基学习机包括:

[0164] 利用基于Bootstrap思想的Bagging对所述训练序列进行重构,生成基学习机PNN网络序列,即一系列差异化的基学习机;

[0165] 对所述一系列差异化的基学习机的权重序列进行初始化。

[0166] 其中,所述的利用基于Bootstrap思想的Bagging对所述训练序列进行重构,生成基学习机PNN网络序列包括:

[0167] 通过Bagging过程,从原始训练数据中生成一个部分重合的序列,用于训练不同的个体PNN网络,进而提高基分类器集合对学习对象的表达能力。

[0168] 其中,所述的通过选择性集成学习,从所述一系列差异化的基学习机中得到训练好的PSOSEN模型包括:

[0169] 在差异化的基学习机生成过程结束后,利用改进的优化算法APSO,根据诊断适应度需求,不断对PNN网络序列的权重向量进行寻优,得到PNN网络的最终权重分布 D_t ;

[0170] 根据所述最终权重分布 D_t ,从所述PNN网络序列中得到训练好的PSOSEN模型。

[0171] 其中,所述的根据最终权重分布 D_t 得到训练好的PSOSEN模型。包括:

[0172] 根据所述最终权重分布 D_t ,选出最终的多个PNN网络;

[0173] 对所述最终的多个PNN网络的全局最优矩阵进行SVD分解,确定所述最终的多个PNN网络所对应的最优权向量参数,从而得到训练好的PSOSEN模型。

[0174] 其中,所述的根据所述最终权重分布 D_t ,选出最终的多个PNN网络包括:

[0175] 将所述最终权重分布 D_t 与预定的阈值进行比较,得到大于阈值的最终权重;

[0176] 将所述PNN网络序列中其最终权重大于阈值的多个PNN网络选作所述最终的多个PNN网络。

[0177] 其中,所述改进的优化算法APSO是引入衰减速度因子和聚合度因子的优化算法PSO。

[0178] 其中,利用所述衰减速度因子和聚合度因子对所述PSO的初始惯性权重进行调节,得到非线性动态惯性递减权重。

[0179] 其中,在所述PNN网络序列的权重向量进行寻优过程中,利用所述非线性动态惯性递减权重自适应地调整搜索空间区域的大小,避免因聚合程度过高而陷入局部最优化的过拟合情况。

[0180] 尽管上文对本发明作了详细说明,但本发明不限于此,本技术领域的技术人员可以根据本发明的原理进行修改,因此,凡按照本发明的原理进行的各种修改都应当理解为落入本发明的保护范围。




图1




图2




图3




图4




图5




图 6




图 7




图8




图9




图10




图11