

基于混合域相对特征和FOA-XGBoost滚动轴承退化评估*

刘晨辉¹, 温广瑞^{1,2}, 苏宇¹, 袁玉姣¹, 黄鑫¹

(1. 西安交通大学机械工程学院 西安, 710049) (2. 新疆大学机械工程学院 乌鲁木齐, 830047)

摘要 针对使用多域特征进行滚动轴承退化评估建模时准确度较低的问题,提出一种基于果蝇优化算法(fruit fly optimization algorithms,简称FOA)集成极限梯度提升树(extreme gradient boosting,简称XGBoost)的轴承退化状态评估方法。提取滚动轴承全寿命周期的时域、频域及时频域等多维特征参数,构建混合域相对特征集,利用相对方均根值初始化轴承退化相应参数,进而利用混合域特征训练XGBoost模型并结合FOA算法对退化评估模型进行参数调优。结果表明:所构建的退化评估模型比常用的支持向量回归(support vector regression,简称SVR)模型在2个数据集上的性能分别提高了27.15%和34.96%,所提方法可以准确有效地评估轴承退化状态。

关键词 混合域相对特征集;果蝇优化算法;极限梯度提升树;轴承退化状态评估

中图分类号 TH17; TP18

引言

旋转机械是工业生产中最为常用的机械之一,广泛应用于电力、化工、冶金等行业。轴承是旋转机械中的重要组成零部件,恶劣的工作环境及工况变化引起的交变载荷极易使轴承发生故障,若不及时采取措施将引发严重事故并造成重大损失^[1]。准确地对轴承运行状态进行评估有利于避免恶性事故的发生,为提高大型旋转机械的安全性、稳定性及可靠性提供有效的科学手段。

由于滚动轴承故障机理复杂,单个特征或单域特征无法准确表征轴承性能退化全周期过程,构建混合域故障特征集成为近年来轴承故障特征提取的发展趋势之一^[2]。丰富的多域特征虽然能够综合地表征全周期轴承的性能退化过程,但非敏感特征和干扰特征的存在将严重影响评估效果。因此,实现对轴承退化较敏感特征的有效选取对轴承的退化评估至关重要。刘鹏等^[3]使用补偿距离评估技术对混合域特征进行特征选择,应用灰色关联分析,对轴承故障程度进行识别。燕晨耀^[4]提取时域、频域、时频域及熵特征构建多维故障特征集,并利用主成分分析对特征集进行降维,结合支持向量回归模型实现轴承的退化状态评估。Zhang等^[5]提出了3种与退

化特征相关的评估标准,分别是相关性、单调性以及鲁棒性指标,将其加权线性组合后作为退化特征的重要性指标。

虽然现有的特征选择方法均取得了不错的应用效果,但这些方法通常用于解决故障分类问题,针对退化过程的特征选择方法研究较少。此外特征选择与退化评估模型建立分步进行也将对所建模型的精度产生较大的影响。近年来,XGBoost作为一种新兴的机器学习算法已经在工程领域得到了广泛的应用,该算法具有精度高、运行速度快及泛化能力强等优点,同时该算法为了在训练过程中提高建模效率,会在每轮迭代时给出各个特征的重要度评分,从而可以自动计算特征的重要性并选择最优特征用于模型的训练^[6]。张钰等^[7]提出将XGBoost应用于轴承故障诊断中,研究结果表明相比其他传统分类器,该算法能够有效提高故障诊断精度和效率。Zhang等^[8]提取风力发电机振动信号的多维特征,使用XGBoost算法建立故障分类模型,结果表明此方法比支持向量机具有更好的诊断效果。XGBoost算法的参数选取对模型的性能影响较大,常用的调参方法往往是基于经验的手动调参,步骤繁多且无法保证多个参数同时达到最优^[9]。很多学者对此提出了改进方法,例如,利用网格搜索或贝叶斯最优化等算

* 国家自然科学基金资助项目(51775409, 51420004);装备预研基金资助项目(6140004030116JW08001);国家重点研发计划资助项目(2017YFF0210504)

收稿日期:2019-05-03;修回日期:2019-06-18

法对XGBoost模型进行参数寻优,结果均表明改进方法要优于人工调优和穷举法^[10-11]。

基于上述情况,笔者提出采用XGBoost模型集成果蝇优化算法进行滚动轴承退化评估,通过提取滚动轴承振动信号的时域、频域以及时频域的混合域相对特征集,标定退化评估值,使用XGBoost建立滚动轴承退化评估模型,并结合FOA算法对其参数进行优化,实现对滚动轴承退化状态的评估。

1 原理

1.1 特征选取

滚动轴承的振动信号包含丰富的状态信息,当轴承性能发生退化时,其时域信号的幅值和概率分布、频域中不同频率的能量和主能量谱峰位置以及时频结构中能量分布都会发生变化。因此文中构造了37维时域、频域以及时频域的混合域故障特征集。时域指标包括均方值、方差、标准差、方根幅值、平均幅值、均方幅值、峰值、峰峰值、偏斜度指标、峭度指标、波形指标、峰值指标、脉冲指标和裕度指标。在频域,文中提取了13个频谱的特征参数^[12]。熵值指标包括时域信息熵和频域信息熵2个信息熵参数^[4]。在时频域,文中提取了信号的8维小波包能量谱特征^[13]。

$$E_j = \sum_{k=1}^M |\omega_j(k)|^2 \quad (1)$$

其中: $\omega_j(k)$ 为对振动信号进行小波包分解3层后各节点的重构信号。

小波包能量谱在时频对信号能量进行划分,能够同时反映信号在时域与频域上的能量分布特征。单一特征或单域特征难以全面刻画轴承运行状态,而混合域特征集中的非敏感特征和干扰特征等无效信息将对后续模型的建立造成困难,因此有必要在建模时对特征集中的特征进行筛选。

1.2 XGBoost算法

极限梯度提升树算法是对传统的梯度提升决策树算法的改进。它的基本思想是把多个准确率较低的模型组合起来构建一个准确率相对更高的模型。该模型可以不断进行迭代计算,每次迭代生成一个新的模型拟合之前模型的误差,这个过程被称为梯度提升。简单而言,提升算法是首先使用简单的模

型得到一个比较一般的结果,然后不断地向模型中添加简单模型,从而提升模型的准确率。

XGBoost模型由多棵决策回归树(classification and regression tree,简称CART)集成,算法原理推导^[14]如下。

假设模型已有 $t-1$ 棵决策树,则第 t 棵决策树可以表示为

$$\hat{y}_i^{(t)} = \sum_{k=1}^t f_k(x_i) = \hat{y}_i^{(t-1)} + f_t(x_i) \quad (2)$$

其中: t 为树的数目; f 为一棵具体的CART树; \hat{y}_i 为预测值; x_i 为输入的第 i 个样本。

目标优化函数为

$$\text{Obj}^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t)}) + \sum_{k=1}^t \Omega(f_k) = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t) + c \quad (3)$$

其中: l 为定义的损失函数; $\Omega(f_t)$ 为模型的复杂度(正则项)。

在一般情况下,将损失函数的泰勒级数推广到2阶并移出常数项,则第 t 步的目标函数变为

$$O^{(t)} = \sum_{i=1}^n [g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i)] + \Omega(f_t) \quad (4)$$

其中: $g_i = \partial_{\hat{y}_i^{(t-1)}} l(y_i, \hat{y}_i^{(t-1)})$; $h_i = \partial_{\hat{y}_i^{(t-1)}}^2 l(y_i, \hat{y}_i^{(t-1)})$; g_i 和 h_i 分别为1阶和2阶导数。

对于一棵决策树,其复杂度可以定义为

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \|\omega\|^2 \quad (5)$$

其中: T 为叶节点的个数; ω 为叶节点上的分直。

对于第 t 棵决策树,当确定一个树结构时可以对目标函数进行求解,得到

$$\omega_j^* = - \frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda} \quad (6)$$

$$O^* = - \frac{1}{2} \sum_{j=1}^T \frac{(\sum_{i \in I_j} g_i)^2}{\sum_{i \in I_j} h_i + \lambda} + \gamma T \quad (7)$$

其中: I_j 为第 j 个叶子节点上的样本集合。

因此,只需要找到使目标函数最小的树结构即可完成第 t 棵决策树模型的建立。

XGBoost采用与决策树类似的信息增益算法实现树结构的确定,即按式(8)遍历计算所有特征的所有切分节点的信息增益,在信息增益最大的切分节点进行分叉,此过程可以并行计算。

$$G = \frac{1}{2} \left[\frac{(\sum_{i \in I_L} g_i)^2}{\sum_{i \in I_L} h_i + \lambda} + \frac{(\sum_{i \in I_R} g_i)^2}{\sum_{i \in I_R} h_i + \lambda} - \frac{(\sum_{i \in I} g_i)^2}{\sum_{i \in I} h_i + \lambda} \right] - \gamma \quad (8)$$

其中： I 为分割前的集合； I_L 和 I_R 为分割后左和右节点的集合。

模型在训练过程中会自动计算各特征被使用的次数总和作为特征的重要性指标。

从以上的原理推导可知，XGBoost算法会随着模型的迭代而不断修正误差，使得该模型拥有很高的精度，同时加入的正则项可以有效地防止模型过拟合。此外，XGBoost算法具有特征选择的功能，可在训练过程中给出特征向量各个特征的评分并优先使用最佳特征进行训练和测试。

1.3 果蝇优化算法

果蝇优化算法是文献[15]提出的一种基于果蝇觅食行为的新型智能优化算法，其基本思想是根据果蝇的位置计算其附近的食物味道浓度，然后向食物味道浓度最大(极大值)或最小(极小值)的地方飞去，通过反复迭代食物味道浓度来求取目标函数的极值。此算法的流程如图1所示。

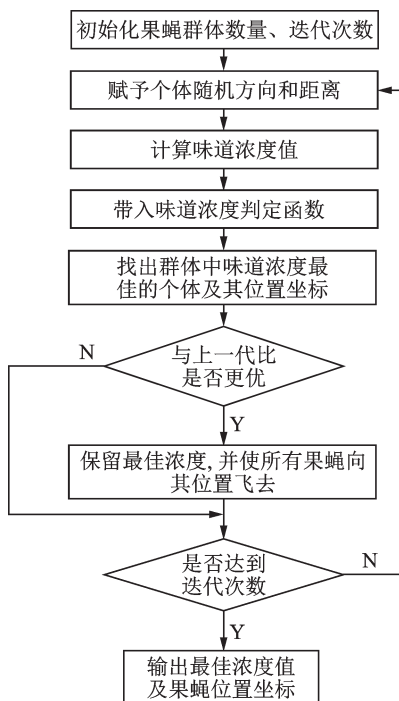


图1 果蝇优化算法流程图

Fig.1 Flow chart of fruit fly optimization algorithm

果蝇优化算法的具体步骤如下：

1) 随机初始化果蝇群体的个数 m 、种群迭代次数 N 和果蝇初始位置 X 及 Y 。

2) 分配果蝇个体搜寻食物的随机方向与距离，式中 $\text{rand}()$ 表示随机数。

$$X(i) = X + \text{rand}(), Y(i) = Y + \text{rand}()$$

3) 由于无法得知食物位置，因此先估计与原点的距离 D ，再以 D 的倒数作为味道浓度判定值带入判定函数，计算味道浓度值即目标函数 S ，并更新每只果蝇的 S 。

$$D(i) = (X(i)^2 + Y(i)^2)^{1/2}$$

$$S = F\left(\frac{1}{D(i)}\right)$$

4) 求出果蝇群中 S 最低的一只，如果其值比上一代最佳浓度值 S_B 要小，则保留其最佳浓度值与坐标，其他果蝇群体向该位置飞去。

5) 迭代寻优步骤2~4，直到最后一代为止。

文中将采用FOA算法对轴承退化评估XGBoost模型的参数进行寻优。

2 滚动轴承退化评估方法

2.1 轴承性能退化指标选取

轴承退化起始时间和轴承退化指标是轴承运行状态评估的关键参数。

国际标准ISO2372中给出机械振动的行业标准：中型机械振动信号的方均根值(root mean square, 简称RMS)达到2.0~2.2 g时，设备将处于危险状态。

轴承个体差异对RMS的影响较大，即使在相同实验条件下不同轴承的RMS也存在较大的差异。如图2所示，正常工作阶段的实验1轴承RMS明显大于实验2轴承。利用原始的RMS无法准确地对不同轴承进行状态评估，因此需要对RMS进行标准化处理。具体流程如下：首先，选取轴承正常工作期内一段趋势平稳RMS，将该段RMS平均值定为标准值；然后，计算原始RMS与标准值之比，得到相对方均根值(relative root mean square, 简称RRMS)^[16]。

从图3可知，RRMS不受轴承个体差异的影响，




图2 实验1和2失效轴承RMS值对比

Fig.2 Comparison of RMS values of failed bearings in test 1 and test 2




图3 实验1和2失效轴承RRMS值对比

Fig.3 Comparison of RRMS values of failed bearings in test 1 and test 2

具有较好的通用性。

笔者使用上述特征标准化方法对滚动轴承全寿命周期振动数据混合域特征进行标准化处理,计算其相对特征来构建混合域相对特征集。

2.2 基于 FOA 和 XGBoost 的轴承退化评估方法

文中所提轴承退化评估方法流程如图 4 所示,具体步骤如下:①提取滚动轴承振动信号多域相对特征,构造混合域故障特征集;②根据轴承的 RRMS 值确定轴承的退化起始时间;③标定轴承退化评估值作为训练样本与验证样本的标签;④使用 XGBoost 算法建立轴承性能退化评估模型,并使用 FOA 算法对模型参数进行寻优;⑤将待诊断信号输入到训练好的模型中,根据模型输出对待诊断轴承退化性能进行评估。

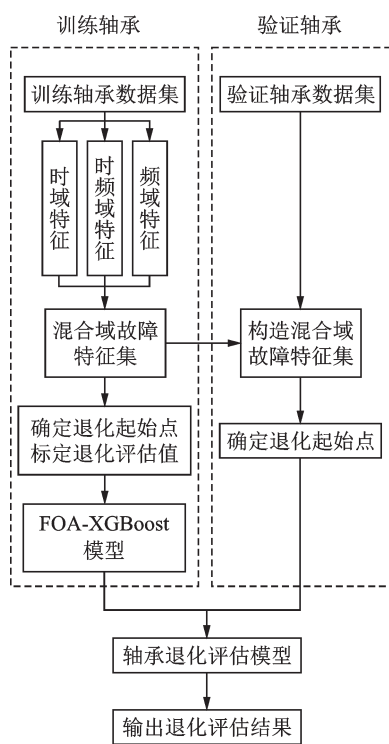


图 4 方法流程图

Fig.4 Method flow chart

3 数据验证及分析

3.1 滚动轴承实验台介绍

文中滚动轴承全寿命周期实验数据来源于 IEEE PHM2012 Data Challenge,由 FEMTO-ST 机构提供^[17],实验平台如图 5 所示。通过运行在不同负载条件下的加速退化实验,在垂直与水平方向获取了多组从良好到失效的轴承全寿命振动信号。振

动信号的采样频率设置为 25 600 Hz,每次采集数据的时间间隔为 10 s,采样时间为 0.1 s,每个样本包含 2 560 个数据点。文中利用工况 1(1 800 r·min⁻¹/4 kN)下轴承 1-1 振动数据作为训练样本,数据长度 2 803,轴承 1-3 的振动数据作为验证样本,数据长度 2 375。




图 5 加速寿命实验台

Fig.5 The setting of accelerated degradation test

3.2 特征提取及数据预处理

3.2.1 特征提取及确定退化起止时间

根据前文介绍的特征提取方法对轴承 1-1 和轴承 1-3 振动信号进行特征提取,构成 37 维混合域特征集。根据不同轴承的 RRMS 值计算轴承退化起始时间。定义 RRMS 值 1.1 为轴承退化的起始时间,定义失效时间为最终失效前 500 s,避免了轴承失效时振动不稳定造成的影响。图 6 和图 7 分别为轴承 1-1 和轴承 1-3 的 RRMS 曲线,图中的红线分别表示轴承的退化起始时间及最终失效时间,其中:轴承 1-1 的退化起始时间为 13 250 s,最终失效时间为 27 530 s,退化数据长度为 1 429;轴承 1-3 的退化起始时间为 11 010 s,最终失效时间为 23 250 s,退化数据长度为 1 225。




图 6 轴承 1-1 的 RRMS 波形图

Fig.6 The RRMS waveform of bearing 1-1




图 7 轴承 1-3 的 RRMS 波形图

Fig.7 The RRMS waveform of bearing 1-3

3.2.2 计算退化评估值

由于不同轴承的退化时间不同,因此无法将时间直接作为退化评估值。文中的退化评估值由式

(9)定义

$$S = 100 - \frac{t - t_0}{t_1 - t_0} \quad (9)$$

其中： S 为退化评估值； t 为当前时刻； t_0 为退化起始时间； t_1 为最终失效时间。

在轴承 1-1 退化数据中均匀选取 100 个点，表示轴承运行状态从 100 到 1 的退化过程。为了避免随机误差造成的影响，同时选取上述 100 个点的前一个点与后一个点作为训练数据。因此训练数据为 100×3 组，标签分别为 100~1。

对轴承 1-3 退化数据同样均匀选取 100 个点作为验证数据，用前文所述方法计算退化评估值作为验证标签进行后续模型的验证。

3.3 实验数据验证

将训练数据及其退化评估值作为训练样本训练 XGBoost 模型并使用验证数据对模型进行验证，同时使用 SVR 模型进行效果对比，结果如图 8 所示。为了对模型效果进行定量比较，采用式 10 所示均方根误差 (root mean square error, 简称 RMSE) 对验证结果进行评价

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (10)$$

其中： y_i 和 \hat{y}_i 分别为真实值和模型输出值； N 为验证样本的总个数。

从图 8 可知，XGBoost 模型的输出结果相比于 SVR 模型的输出结果更贴近实际评估值曲线。计算得到的 2 个模型的 RMSE 值，SVR 模型的 RMSE 为 6.607，而 XGBoost 模型的 RMSE 为 4.629。从定义可知，模型效果越好 RMSE 就越接近 0，表明 XGBoost 模型在轴承退化评估方面要明显优于 SVR 模型，效果提高了 29.94%。

图 9 所示为 XGBoost 模型训练时各特征的评分，分别挑选其中评分最高和最低的 4 个特征进行




图 8 SVR 模型与 XGBoost 模型输出结果对比

Fig.8 Comparison of output results between SVR model and XGBoost model




图 9 特征评分

Fig.9 Feature score

分析。

通过模型训练给出的 4 个评分最高的特征分别为标准化后的方根幅值、频域第 10 维特征、峰值和方均根值。从图 10 可知，信号很好地反映了滚动轴承 1-1 在全生命周期里的整体性能变化趋势，信号具有良好的单调性且噪音干扰少，十分适合退化评估的分析。

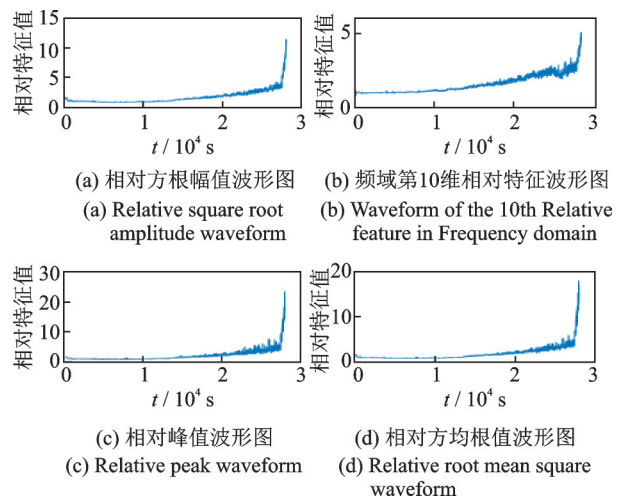


图 10 4 个最优特征波形图

Fig.10 Four best feature waveforms

4 个评分最低的特征分别为标准化后的频域第 3 维特征、小波包能量谱第 7 维特征、频域第 4 维特征和频域第 1 维特征。从图 11 可知，信号含有很强的噪音干扰或者与退化趋势毫无关系，不能很好地反映轴承的退化状态信息。

为了证明特征选择的有效性，按照特征重要程度逐渐增加特征维数输入到 XGBoost 模型进行训练与测试，计算每次输出值的 RMSE 值，结果如图 12 所示。从图中可知，在输入约 9 维特征时，模型 RMSE 值达到 4.6 左右的稳定值。分别对输入 9 维特征时与输入 37 维特征时的建模时间进行计算，得到输入 37 维特征时，训练与验证时间为 0.128 66 s；

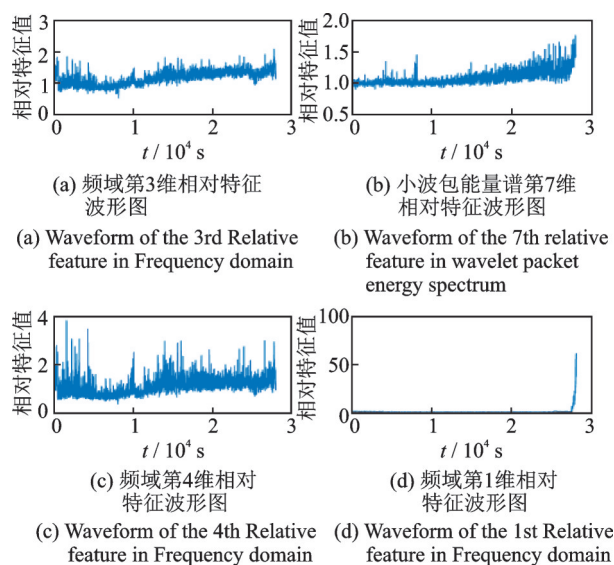


图 11 4 个最差特征波形图

Fig.11 Four worst feature waveforms




图 12 模型输出误差与特征维数关系图

Fig.12 The relationship between model output error and characteristic dimension

输入 9 维特征时,训练与验证时间为 0.042 89 s。可见,在保证算法性能的情况下,计算效率得到了显著提高。

XGBoost 算法使用了十几个参数,参数的调整对于提高模型性能十分重要,手动调参不能保证多个参数同时达到最优,因此有必要采用智能优化算法对相关参数进行动态选取与调整。文中采用果蝇优化算法对 XGBoost 模型 5 个重要参数进行调优^[9],参数的详细信息如表 1 所示。其中:学习率指

表 1 XGBoost 算法的主要参数及说明

Tab.1 Main parameters and description of XG-Boost algorithm

序号	参数名称	中文含义	优化后参数值
1	learning_rate	学习率	0.423
2	Gamma	最小损失函数值	0.108
3	reg_lambda	正则项中的 λ	0.371
4	reg_alpha	正则项中的 γ	0.452
5	min_child_weight	最小叶子节点权重和	0.800

后一个学习器对前一个学习器产生误差的学习步长;最小损失函数指信息增益 Gain 小于多少时停止分裂,最小叶子节点权重和即算法原理中的 $\sum_{i \in I_j} g_i$ 。

将训练样本中的前 200 个样本作为训练数据,后 100 个样本作为测试数据,使用 RMSE 值作为适应度函数对 XGBoost 模型参数进行调优。设置果蝇种群数量为 30,迭代次数为 100。图 13 所示为 FOA 算法优化 XGBoost 模型的迭代收敛过程。从图中可知,FOA 算法在迭代前期适应度函数值急剧下降,在迭代 50 次左右时达到收敛值。将 FOA 算法优化前后的 XGBoost 模型进行对比,同时使用 FOA 算法对 SVR 模型的惩罚因子 C 和核函数参数 σ 进行优化后与 FOA-XGBoost 模型进行对比。经过优化后的 SVR 模型参数为 $C=4.012, \sigma=0.257$ 。




图 13 FOA 收敛过程

Fig.13 Convergence process of FOA

使用 FOA 算法进行参数优化前后的 XGBoost 模型的输出结果对比如图 14 所示。从图中可知,FOA-XGBoost 模型的输出更加接近实际退化评估曲线。图 15 所示为 FOA-SVR 模型与 FOA-XGBoost 模型的输出结果对比。从图中看出,FOA-XGBoost 模型具有更好的输出结果。通过计算,FOA-SVR 模型输出值的 RMSE 为 5.092,比 FOA




图 14 XGBoost 模型与 FOA-XGBoost 模型输出结果对比
Fig.14 Comparison of output results between XGBoost model and FOA-XGBoost model




图15 FOA-SVR模型与FOA-XGBoost模型输出结果对比
Fig.15 Comparison of output results between FOA-SVR model and FOA-XGBoost model

模型效果提高了22.93%，FOA-XGBoost模型输出值的RMSE为3.710，比XGBoost模型效果提高了19.86%，说明FOA算法可以有效地对模型参数优化。FOA-XGBoost模型比FOA-SVR模型的效果提高了27.15%，说明XGBoost模型比传统的SVR模型更加适合滚动轴承的退化性能评估。

为了进一步验证该方法的通用性，使用西安交通大学与昇阳科技共同成立的机械装备健康监测联合实验室提供的XJTU-SY轴承数据集对模型进行验证^[18]。该数据集包含3类实验工况，每类工况各测试5个轴承，共15个轴承的全寿命周期信号。采样间隔为1 min，采样频率为25.6 kHz，采样时间为1.28 s。表2列出了文中选用数据的详细信息。

表2 轴承的工况及振动信息

Tab.2 Bearing operating condition and vibration information

工况	轴承名称	数据长度	失效类型
35 Hz/12 kN	1-1	123	外圈故障
	1-2	161	外圈故障
	1-3	158	外圈故障
	1-5	52	内圈和外圈故障

同样采取之前的方法对实验轴承进行数据选取，将失效前两分钟设为轴承最终失效时间，由于退化数据长度较短，因此轴承1-1选取50个点，轴承1-2选取100个点，轴承1-3选取50个点，轴承1-5选取10个点。将轴承1-1,1-3,1-5的退化数据作为训练集并在其中随机选取1/3的数据集作为验证集进行交叉验证实现参数调优，轴承1-2的退化数据作为验证集进行模型验证，参数优化后的模型效果对比如图16所示。可以看出，FOA-XGBoost模型相比于FOA-SVR模型更加接近实际退化评估曲线。计算得到FOA-SVR模型与FOA-XGBoost模型输出

值的RMSE分别为13.268 7和8.629 7，效果提高了34.96%。结果表明，FOA-XGBoost模型可以准确地对滚动轴承退化状态进行评估。




图16 FOA-SVR模型与FOA-XGBoost模型在XJTU-SY数据集上输出结果对比
Fig.16 Comparison of output results on XJTU-SY dataset between FOA-SVR model and FOA-XGBoost model

4 结束语

针对利用多域特征进行轴承退化评估建模时准确度较低的问题，笔者提出了基于混合域相对特征和FOA-XGBoost模型的滚动轴承退化状态评估方法。在两个不同的数据集上的实际测试结果表明，该方法输出误差小、泛化能力强，能够更准确地评估滚动轴承退化状态，所提方法具有以下特点：①标准化后的相对特征消除了轴承个体差异的影响，能更准确地表征轴承的运行状态；②XGBoost算法可以在训练时优先选取较好的特征进行建模，避免了无效特征及干扰特征的影响；使用果蝇优化算法对模型参数进行调优，可以有效地提高模型的性能；③通过与FOA-SVR模型的对比，FOA-XGBoost模型可以准确有效地评估轴承的退化状态。

参 考 文 献

- [1] PATIL M S, MATHEW J, RAJENDRA K P K. Bearing signature analysis as a medium for fault detection: a review [J]. Journal of Tribology, 2008, 130(1): 014001.
- [2] 王奉涛, 陈旭涛, 柳晨曦, 等. 基于KPCA和WPHM的滚动轴承可靠性评估与寿命预测[J]. 振动、测试与诊断, 2017, 37(3): 476-483.
WANG Fengtao, CHEN Xutao, LIU Chenxi, et al. Rolling bearing reliability assessment and life prediction-Based on KPCA and WPHM [J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37(3): 476-483. (in Chinese)
- [3] 刘鹏, 李洪儒, 王卫国, 等. 基于补偿距离评估技术与

- 灰色关联分析的滚动轴承故障程度识别[J]. 机械传动, 2015, 39(10): 97-100.
- LIU Peng, LI Hongru, WANG Weiguo, et al. Fault severity recognition of rolling bearing based on compensation distance evaluation technique and grey relational analysis[J]. Journal of Mechanical Transmission, 2015, 39(10): 97-100. (in Chinese)
- [4] 燕晨耀. 基于多特征量的滚动轴承退化状态评估和剩余寿命预测方法研究[D]. 成都: 电子科技大学, 2016.
- [5] ZHANG B, ZHANG L, XU J. Degradation feature selection for remaining useful life prediction of rolling element bearings [J]. Quality and Reliability Engineering International, 2016, 32(2): 547-554.
- [6] 宋国琴, 刘斌. 基于XGBoost特征选择的慕课翘课指数建立及应用[J]. 电子科技大学学报, 2018, 47(6): 123-128.
- SONG Guoqin, LIU Bin. The establishment and application of drop-out-index of MOOCs based on XGBoost feature selection[J]. Journal of University of Electronic Science and Technology of China, 2018, 47(6): 123-128. (in Chinese)
- [7] 张钰, 陈珺, 王晓峰, 等. Xgboost在滚动轴承故障诊断中的应用[J]. 噪声与振动控制, 2017, 37(4): 166-170.
- ZHANG Yu, CHEN Jun, WANG Xiaofeng, et al. Application of Xgboost to fault diagnosis of rolling bearings [J]. Noise and Vibration Control, 2017, 37(4): 166-170. (in Chinese)
- [8] ZHANG D, QIAN L, MAO B, et al. A data-driven design for fault detection of wind turbines using random forests and XGBoost [J]. IEEE Access, 2018, 6: 21020-21031.
- [9] 王桂兰, 赵洪山, 米增强. XGBoost算法在风机主轴承故障预测中的应用[J]. 电力自动化设备, 2019, 39(1): 73-77.
- WANG Guilan, ZHAO Hongshan, MI Zengqiang. Application of XGBoost algorithm in prediction of wind motor main bearing fault [J]. Electric Power Automation Equipment, 2019, 39(1): 73-77. (in Chinese)
- [10] 赵天傲, 郑山红, 李万龙, 等. 基于XGBoost的信用风险分析的研究[J]. 软件工程, 2018, 21(6): 29-32.
- ZHAO Tianao, ZHENG Shanhong, LI Wanlong, et al. A study of the credit risk analysis based on XGBoost [J]. Software Engineering, 2018, 21(6): 29-32. (in Chinese)
- [11] 李叶紫, 王振友, 周怡璐, 等. 基于贝叶斯最优化的Xgboost算法的改进及应用[J]. 广东工业大学学报, 2018, 35(1): 23-28.
- LI Yezi, WANG Zhenyou, ZHOU Yilu, et al. The improvement and application of Xgboost method based on the bayesian optimization [J]. Journal of Guangdong University of Technology, 2018, 35(1): 23-28. (in Chinese)
- [12] 雷亚国, 何正嘉, 瞿艳阳. 基于混合智能新模型的故障诊断[J]. 机械工程学报, 2008, 44(7): 112-117.
- LEI Yaguo, HE Zhengjia, ZI Yanyang. Fault diagnosis based on novel hybrid intelligent model [J]. Chinese Journal of Mechanical Engineering, 2008, 44(7): 112-117. (in Chinese)
- [13] 王冬云, 张文志, 张建刚. 小波包能量谱在滚动轴承故障诊断中的应用[J]. 轴承, 2010(11): 32-36.
- WANG Dongyun, ZHANG Wenzhi, ZHANG Jianguang. Application of wavelet packet energy spectrum in rolling bearing fault diagnosis [J]. Bearing, 2010(11): 32-36. (in Chinese)
- [14] CHEN T, GUESTRIN C. XGBoost: a scalable tree boosting system [C]//Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, USA: Association for Computing Machinery, 2016: 785-794.
- [15] PAN W T. A new fruit fly optimization algorithm: taking the financial distress model as an example [J]. Knowledge-Based Systems, 2012, 26(2): 69-74.
- [16] 申中杰, 陈雪峰, 何正嘉, 等. 基于相对特征和多变量支持向量机的滚动轴承剩余寿命预测[J]. 机械工程学报, 2013, 49(2): 183-189.
- SHEN Zhongjie, CHEN Xuefeng, HE Zhengjia, et al. Remaining life prognostics of rolling bearing based on relative features and multivariable support vector machine [J]. Journal of Mechanical Engineering, 2013, 49(2): 183-189. (in Chinese)
- [17] NECTOUX P, GOURIVEAU R, MEDJAHHER K, et al. Pronostia: an experimental platform for bearings accelerated life test [C]//Proceedings of the IEEE International Conference on Prognostics and Health Management. Washington, DC, USA: IEEE, 2012: 1-8.
- [18] WANG B, LEI Y, LI N, et al. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings [J]. IEEE Transactions on Reliability, 2018, 69(1): 401-412.



第一作者简介:刘晨辉,男,1995年5月生,硕士生。主要研究方向为机械运行状态故障诊断及性能维护。

E-mail: liuchenhui@mail.xjtu.edu.cn