DOI：10.13890/j.issn.1000-128X.2023.03.011　　文章编号：1000-128X(2023)03-0090-07

基于优化Bray-Curtis相异度和PSO算法的轴承剩余寿命预测方法研究

李权福[1,2]，贾　晨[2]，宋冬利[2]，徐　潇[2]
（1.国能铁路装备有限责任公司，北京　100089；
2.西南交通大学 轨道交通运载系统全国重点实验室，四川 成都　610031）

摘　要：轴承在车辆运行过程中既承受载荷又传递载荷，工作环境非常恶劣，若发生故障，会严重威胁车辆的正常运行安全，因此对轴承开展剩余寿命预测方法研究具有重大意义。文章提出了采用稀疏自编码器和Bray-Curtis相异度相结合的方式构建新的轴承健康指标集，并利用改进后的粒子群优化（Particle Swarm Optimization, PSO）算法建立轴承退化模型，最后对测试轴承的剩余寿命进行预测。首先，将轴承健康样本及实测数据的各特征指标输入到稀疏自编码器中进行训练，提取出2种轴承特征参数，计算Bray-Curtis相异度差值作为新的健康指标；然后，基于改进后PSO算法建立轴承退化模型；最后，依据新的健康指标对实测状态下的轴承进行剩余寿命预测。结果表明：该退化模型的拟合曲线预测精度较高，其性能退化曲线与实际轴承退化情况较为接近，可以较好地预测轴承的剩余寿命。

关键词：Bray-Curtis相异度；PSO算法；退化模型；剩余寿命预测
中图分类号：U270.331^{+}.2　　**文献标识码：**A

A study on method for bearing residual life prediction based on optimized Bray-Curtis dissimilarity and PSO algorithms

LI Quanfu[1,2], JIA Chen[2], SONG Dongli[2], XU Xiao[2]

(1. CHN ENERGY Railway Equipment Co., Ltd., Beijing 100089, China; 2. State Key Laboratory of Rail Transit Vehicle System, Southwest Jiaotong University, Chengdu, Sichuan 610031, China)

Abstract: Bearings work under a very harsh environment since they do not only bear load but also transfer load during vehicle operation. The occurrence of failure will seriously threaten the safety of vehicles in normal operation. From this perspective, the study of the method for bearing residual life prediction is of great significance. In this paper, a new bearing health index set was set up by combining the sparse autoencoder (SAE) and the Bray-Curtis dissimilarity algorithm, and the bearing degradation model was established by using the improved particle swarm optimization (PSO) algorithm, to predict the residual life of the tested bearings. Firstly, the characteristic indexes of healthy bearing samples and measured data were inputted into the SAE for training, from which two kinds of characteristic parameters for bearing were extracted, to calculate the Bray-Curtis dissimilarity difference which was then taken as a new health index. Then, the bearing degradation model was established based on the improved PSO algorithm. Finally, the new health index was used to predict the residual life of the bearings under real measurement. The results show that the fitting curve of the model has high prediction accuracy, and the performance degradation curve is close to the actual bearing degradation, so that the model can be used to predict the bearing residual life more effectively.

Keywords: Bray-Curtis dissimilarity; PSO algorithm; degradation model; residual life prediction

---

基金项目：国家能源集团科技创新项目（SHGF-17-54）
通信作者：贾　晨（1999—），男，硕士研究生，主要从事轴承故障诊断方面的研究；E-mail: 1012998675@qq.com
引用格式：李权福, 贾晨, 宋冬利, 等. 基于优化Bray-Curtis相异度和PSO算法的轴承剩余寿命预测方法研究[J]. 机车电传动, 2023(3): 90-96.
Citation: LI Quanfu, JIA Chen, SONG Dongli, et al. A study on method for bearing residual life prediction based on optimized Bray-Curtis dissimilarity and PSO algorithms[J]. Electric Drive for Locomotives,2023(3): 90-96.

0　引言

轴承作为列车走行部最关键的零部件之一，在运行过程中既承受载荷又传递载荷，工作环境非常恶劣，若发生故障，会严重威胁车辆的正常运行安全[1]。因此，轴承在线监测对于设备的状态监测和事故预防具有重要作用。

针对轴承剩余寿命预测研究方法可大致划分为3种：①基于失效原理的方法；②基于数据驱动的方法；③以上两者相结合的寿命预测方法[2]。基于失效原理的方法，采用物理模型对轴承的寿命进行预测，该预测方法可以得到更准确的结果[3]。目前，国内外通行的滚动轴承疲劳寿命预测公式仍然以G.Lunderg和A.Palmgren[4]在1949年提出的最大动态切应力理论为基础，在后期的实践中证明了Lundberg-Palmgren方法可以有效地进行滚动轴承剩余寿命预测，但是仍然存在着一些缺陷。当难以获取零部件的足够寿命数据时，基于失效原理的方法可以根据零部件存在的某些性能特征与可靠性之间的关系建立退化模型，从而评估该零部件的可靠性[5]，但由于需要进行损伤力学分析和传感器监测采集数据，普适性较差，操作难度较高，专业要求较高，在预测应用上不如数据驱动的方法广泛。

在当前科技发展快速的时代，基于数据驱动的方法成为目前最常见的剩余寿命预测（Remaining Useful Life, RUL）方法，其原理主要是通过机器学习算法，构建基于传感器的监测数据和剩余使用寿命之间的映射关系[6]，自HINTON等[7]提出深度学习理论后，深度神经网络以其强大的特征自提取能力影响了很多领域的发展。文献[8]将振动信号输入到由卷积神经网络和长短时记忆单元构成的神经网络中获取健康指标，对轴承退化过程进行表征。文献[9]使用SOM融合特征构建健康指标，并引入缩放参数统一失效阈值，通过粒子滤波器预测剩余使用寿命。但是基于机器学习的方法需要大量高质量的训练样本，工程上在获取这些数据方面存在困难。

由于上述2种方法的局限性，本文提出了一种结合两者的优点，并基于优化Bray-Curtis相异度和粒子群优化（Particle Swarm Optimization, PSO）算法的轴承退化规律与寿命预测方法。该方法对轴承进行在线状态监测，根据在线监测的相关数据，判断轴承的性能退化情况，并建立相关机理模型对轴承进行剩余寿命预测，实现对轴承的全寿命周期的可靠性研究。

1　轴承全寿命周期试验介绍

由于轴承的全寿命周期试验周期较长，并且全寿命周期试验的数据量较大，所以一般的轴承台架试验难以开展轴承的全寿命周期试验。因此，本文所选的台架试验轴承的全寿命周期数据为辛辛那提大学轴承试验数据[10]，图1为轴承台架试验实物及原理图。该试验选用了4个相同型号的双列滚子轴承，对每个被试验轴承施加了2 721.6×9.8 N（6 000 lbs.）的径向载荷，由交流电动机通过皮带传动驱动，转速恒定为2 000 r/min。试验采集了每个轴承从试验开始到完全失效的全过程的振动加速度数据，采样频率为20 kHz，试验时长约为10 000 min，采样点共计2×10^8个。考虑到全生命周期试验的振动加速度数据量较大，导致计算时间较长，因此对轴承振动加速数据按照1:10的比例进行压缩，最后共选取采样点约为2×10^7个。

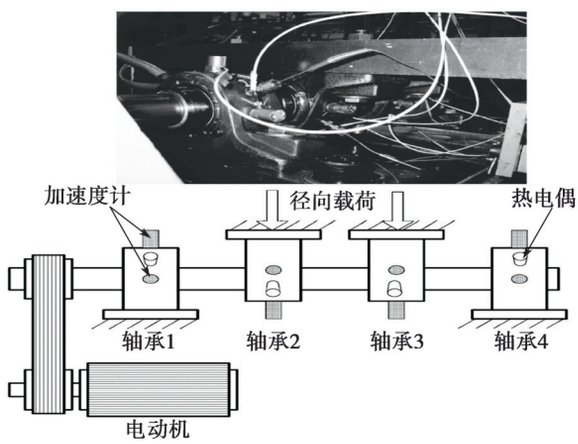
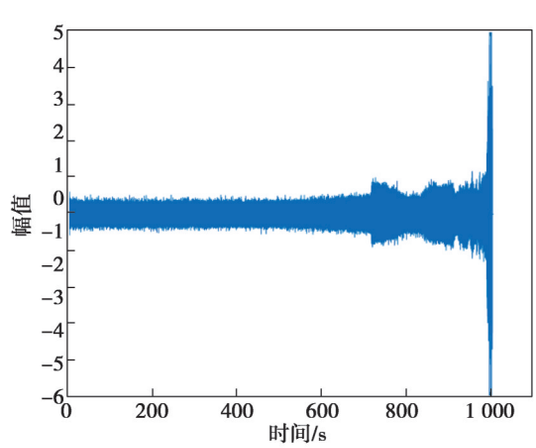


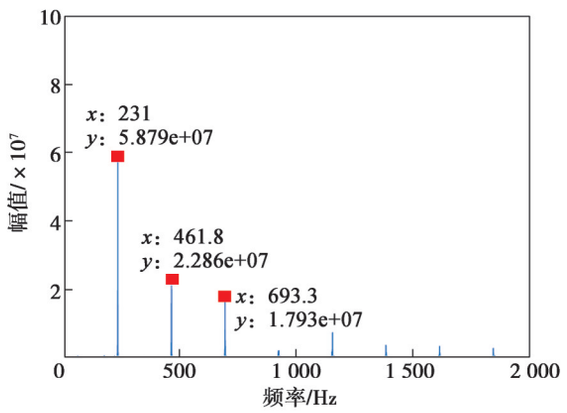
图1　轴承试验及原理图

Fig. 1　Schematic diagram of bearing test

图2(a)为由压缩后的振动加速度试验数据集提取的1#轴承振动信号时域图，选取的振动信号点数量为20 152 320个，采样时间约为1 000 s。由图2(a)可知，在试验最后的300 s内，轴承振动信号的幅值有扩大现象，初步推测此阶段的试验轴承发生了故障，最后达到了完全失效。图2(b)为1#轴承振动信号包络谱图。在图2(b)中，存在明显的轴承外圈故障特征主频，并且故障特征频的2倍频、3倍频和4倍频均较为明显。



(a) 试验轴承振动信号时域图



(b) 试验轴承振动信号包络谱图

图2 试验轴承振动信号特征

Fig. 2 Features of vibration signal of tested bearing

2 基于优化的Bray-Curtis相异度轴承健康指标构建

开展轴承全寿命周期可靠性研究和寿命预测工作，需要确定轴承早期故障发生的时间点t_{ftp}，并以此作为预测起始点，从振动加速度信号中获取轴承的特征参数构建轴承的健康指标。轴承振动加速度信号成分较为复杂，要对轴承进行剩余寿命预测，需从轴承振动加速度信号里提取出轴承的健康状态信息，构建轴箱轴承健康指标，从而分析服役过程中轴箱轴承的性能劣化趋势[11]。滚动轴承健康指标大多为振动信号的时域指标，如振动加速度的方均根值、方差值、标准差值以及峭度值等[12]，其中最基本的滚动轴承健康指标为方均根值。图3为整个试验过程中轴承的振动加速度方均根值变化过程。如图3所示，轴承的性能变化主要分为4个阶段：正常运转阶段、早期故障阶段、故障磨合阶段、加速退化阶段[13]。当早期故障出现时，轴承的退化速度加快；经过故障磨合后退化趋势有所缓和；最后经历加速退化使得轴承性能急剧退化直至失效。

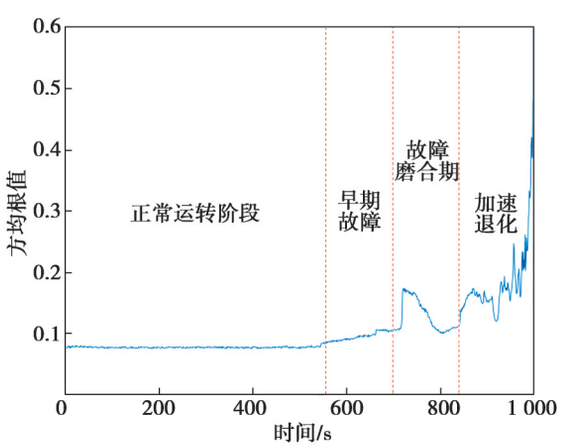


图3 轴承性能退化趋势图

Fig. 3 Trend of bearing performance degradation

目前，传统健康指标构建方法存在以下缺点：①当选取时域指标作为健康指标时，对轴承试验数据有着较高的要求，而实际线路的轴承数据可能会受轮轨激励的影响使得噪声较大，需要进行一定的降噪处理；②选用某一时域指标作为健康指标具有较强的主观性，需要在不同的时域指标中人为选择与退化模型拟合程度最高的一种作为健康指标，工作内容复杂，工作量极大。

为此，本文提出一种基于稀疏自编码器和Bray-Curtis相异度结合的健康指标构建方法。该方法将轴承正常状态的时域指标输入到稀疏自编码器训练中得到健康状态特征，再将实际所测轴承的试验数据输入到稀疏自编码器中获得实际轴承健康状态特征，计算2种状态下的Bray-Curtis相异度差值作为轴承的新健康指标，可以有效地解决时域健康指标主观选择性，并且有效降低环境噪声对健康指标的影响。

2.1 稀疏自编码器原理

稀疏自编码器是一种无监督机器学习算法，其网络结构如图4所示。通过计算自编码的输出与原输入的误差，不断调节自编码器的参数，最终训练出模型[13]。

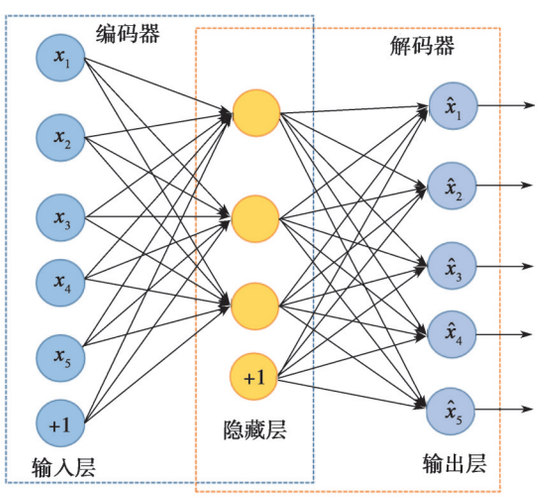


图4 稀疏自编码器网络结构

Fig. 4 Network structure of sparse autoencoder(SAE)

假设隐层节点数大于输入层节点数，隐层激活函数采用的是sigmoid，同时期望得到输入数据内一些有趣的结构和规律，那么隐层输出为“1”时代表该节点“活跃”，隐层输出为“0”时代表该节点“不活跃”。基于此，引入KL离散度来衡量某个隐层节点的平均激活输出与所设定的稀疏度ρ之间的相似性：

$$\left.\begin{aligned}&\mathrm{KL}\left(\rho\,\|\,\hat{\rho}_j\right)=\rho\log\frac{\rho}{\hat{\rho}_j}+\left(1-\rho\right)\log\frac{1-\rho}{1-\hat{\rho}_j}\\&\hat{\rho}_j=\frac{1}{m}\sum_{i=1}^{m}\left[a_j^{(2)}x^{(i)}\right]\end{aligned}\right\}\tag{1}$$

式中：m为训练样本的个数；$\hat{\rho}_j$为第j个神经元的平均激活度；ρ为1个表示稀疏性的参数；$a_j^{(2)}x^{(i)}$为隐层第j个节点对i个样本的相应输出。

KL离散度越大代表ρ和$\hat{\rho}_j$之间相差越大；KL离散度等于0，代表$\rho=\hat{\rho}_j$，两者完全相等。通常设定稀疏度ρ为0.05或0.1。为约束整个自编码器网络的稀疏性[15]，将KL离散度作为正则项加入到损失函数中，总体代价函数可表示为

$$J_{\text{sparse}}(W,b)=J(W,b)+\beta\sum_{j=1}^{s_2}\text{KL}\left(\rho\,\|\,\hat{\rho}_j\right) \tag{2}$$

式中：$J(W,b)$为神经网络的损失函数；S_2为隐藏层中隐藏神经元的数量；$\sum_{j=1}^{s_2}\text{KL}\left(\rho\,\|\,\hat{\rho}_j\right)$为惩罚因子；$\beta$为控制惩罚因子权重的参数。

2.2　轴承健康状态特征参数获取

稀疏自编码器提取轴承特征参数的流程主要分为离线阶段和在线阶段。其中，离线阶段获取不同时段的轴承特征参数，在线阶段通过自编码器训练获取最优参数，具体步骤如下：

①采集轴承全寿命振动加速度信号。

②计算振动加速度信号的各时域特征指标，如方均根值、方差值和标准差值等。

③将n个时域特征指标作为输入节点在稀疏自编码器中进行训练，得到$n-1$个神经元输出，并计算输入与输出节点的误差。

④将$n-1$个神经元数据再次作为输入节点放入稀疏自编码中训练，重复步骤③进行降维操作，当输出节点数为1时得到的输出参数，即可作为该轴承的特征参数。

利用稀疏自编码器提取的轴承特征参数具有客观性，可实现无监督式的特征提取，并通过计算自编码的输出与原输入的误差，不断对轴承的特征参数进行降维训练，最终训练出最优轴承特征参数，获取得到的特征参数图像如图5所示。

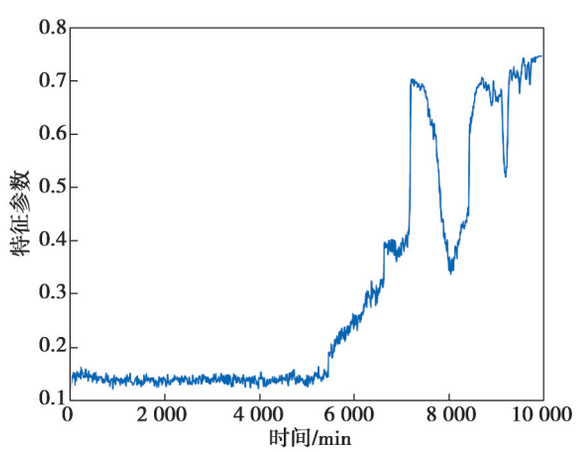


图5　自编码器获取的轴承特征参数

Fig. 5　Characteristic parameters of bearing obtained by the SAE

2.3　基于Bray-Curtis相异度的健康指标构建

从图5可以看出，试验轴承在早期处于正常状态运行时其噪声较为明显，这样会使得轴承特征参数波动较大，在试验前期难以通过方均根值和稀疏自编码器提取到特征参数图像以辨识早期故障。由此导致在后续拟合退化曲线时，前期正常运行状态下的健康指标与拟合曲线产生较大误差，造成拟合曲线的拟合优度下降。因此，提出一种基于Bray-Curtis相异度的健康指标优化方法，这种健康指标构建方法可以有效减小因前期正常运行状态的健康指标而导致的误差。

Bray-Curtis相异度是生态学常用的度量指标，可以根据物种组成计算2个生物群落之间的相似度。利用Bray-Curtis相异度计算时，不仅考虑物种的有无，还考虑了不同物种的相对丰度[16]。对应轴承健康指标构建问题，Bray-Curtis相异度可以衡量健康状态特征和退化状态特征之间对应特征值的有无及大小差异，同时具有将差异程度归一化的特点，消除量纲的影响。与欧氏距离相比，受特征值大小的影响较小，其计算公式为

$$d_{ij}=\sum_{k=1}^{m}\left|x_{ik}-x_{jk}\right|\Big/\sum_{k=1}^{m}\left|x_{ik}+x_{jk}\right| \tag{3}$$

式中：x_{ik}为健康特征状态的第k个特征值；x_{jk}为退化特征状态的第k个特征值。

该差值的取值在[0,1]，越接近“0”表示2个特征之间的差异越小，轴承越健康；越接近“1”表示2个特征之间的差异越大，轴承越接近完全失效。

由图3可知，本文所选用的IMS轴承全寿命周期数据在0~5 000 min内轴承处于正常状态，5 000 min之后轴承出现早期故障，直至最终完全失效。因此，将前文中稀疏自编码器提取的轴承特征参数数据分为0~5 000 min和5 000~10 000 min这2段，前半段为轴承正常运转特征参数，后半段为轴承退化特征参数。将这2段数据平均分为100组，每组可得到5个特征值，按式(3)计算2段数据的Bray-Curtis相异度，得到最终的健康指标函数图像，如图6所示。相比于图3的方均根值健康指标，该方法通过计算Bray-Curtis相异度差值可以对轴承数据做出筛选，筛掉轴承正常状态的数据，

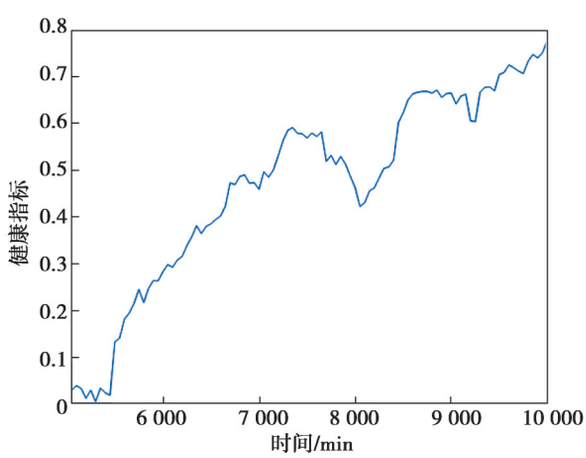


图6　Bray-Curtis相异度健康指标

Fig. 6　Bray-Curtis dissimilarity health index

并保留从早期故障开始到完全退化阶段的有效数据，健康指标具有更好的单调性和趋势性，可以较好地反映轴承的退化情况，并且可以更精确地识别轴承早期故障起始点和轴承各退化阶段的分布情况，为后续计算退化模型参数和轴承剩余寿命提供理论支撑。

3 粒子群优化(PSO)算法原理及改进

粒子群优化 (PSO) 算法属于群智能算法的一种，是通过模拟鸟群捕食行为设计的。该算法通过设计一种无质量的粒子来模拟鸟群中的鸟，粒子仅具有2个属性：速度和位置。每个粒子在搜索空间中单独搜寻最优解，并将个体极值与整个粒子群里的其他粒子共享，找到最优的个体极值作为整个粒子群的当前全局最优解，通过共享得到的全局最优解可以使得所有粒子都能适当改变自己的属性[17]。粒子群优化算法的主要步骤如下[具体公式如式(4)和式(5)所示]：

①初始化粒子群。

②评估每个粒子，并得到全局最优。

③更新粒子的速度和位置，经过对初始化粒子的多次迭代得到最优解。

④评估每个粒子的函数适应值，当达到最大迭代次数或全局最优位置满足最小界限时停止迭代，将最后的全局最优位置作为该粒子群的最优解输出。

$$v_{i+1}=v_i\times w+c_1\times r_1\times\left(p_{i,\mathrm{pbest}}-x_i\right)+c_2\times r_2\times\left(p_{i,\mathrm{gbest}}-x_i\right) \tag{4}$$

$$x_{i+1}=x_i+v_i \tag{5}$$

式中：$i=1,2,\cdots,N$，N为微粒群中粒子总数；v_i为粒子当前的速度；x_i为粒子当前的位置；w为惯性权重；c_1为个体学习因子；c_2为群体学习因子，通常取$c_1=c_2=2$；r_1,r_2为介于(0, 1)的随机数；$p_{i,\mathrm{pbest}}$为微粒群的局部最优值；$p_{i,\mathrm{gbest}}$为微粒群的全局最优值。

式(4)和式(5)是PSO算法的标准形式，PSO优化算法原理简单，收敛速度快，设置参数少，但存在易早熟收敛至局部最优和迭代后期收敛速度慢的问题，从而导致拟合双指数模型参数出现较大误差，对后续预测寿命效果不佳。为避免PSO算法的参数估计结果陷入局部最优的情况，将自适应算法引入PSO算法中，在寻优初期使用较大的惯性权重，具有较强的全局搜索能力，后期采用较小的惯性权重提高局部发掘能力，自适应惯性系数变化公式为

$$w=\left(w_{\max}-w_{\min}\right)\mathrm{e}^{-\left(\tau\times\frac{k}{k_{\max}}\right)^2}+w_{\min} \tag{6}$$

式中：$w_{\max}$为最大惯性权重；$w_{\min}$为最小惯性权重；k为当前迭代次数；$k_{\max}$为算法迭代总次数；τ为1个经验值，一般取[20,55]内的任意值。

当适应度函数中出现多极值的情况，惯性权重过大容易导致“早熟收敛”与算法后期在全局最优解附近产生振荡的现象。因此，采用随机权重策略对自适应PSO算法进行改进，其表达式为

$$w=r_1\left(w_{\max}-w_{\min}\right)\mathrm{e}^{-\left(\tau\times\frac{k}{k_{\max}}\right)^2}+\sigma\times r_\sigma(0,1) \tag{7}$$

式中：σ为随机权重平均值的方差；$r_\sigma(0,1)$为(0, 1)内服从正态分布的随机数。

4 轴承退化模型建立与剩余寿命预测

在目前的基本退化评估方法中，采用构建指数退化模型的方法来评估退化信号是较常用的一种[17]。双指数模型拟合的是水平项和趋势项时序，其预测结果是一条具有斜率的直线，按前文所建立的健康指标趋势更贴近一条具有斜率的直线，故可以采用双指数模型对健康指标进行拟合，双指数模型的表达式为

$$Y=a^{bt}+c^{dt} \tag{8}$$

式中：Y为双指数模型拟合值；t为轴承衰退时间；a,b,c,d为模型参数。

4.1 双指数模型参数估计

利用改良后的PSO算法对双指数模型的4个参数进行寻优，将观测值与拟合值的方均误差函数作为适应度函数代入PSO算法模型中，其适应度函数为

$$\varepsilon=\frac{1}{M\sum_{i=1}^{M}\left(y_i-Y_i\right)^2} \tag{9}$$

式中：M为观测点总数；y_i, Y_i分别表示第i个健康指标点的实际值和双指数模型的拟合值。

在前文构建的轴承健康指标数据中选取20个数据点作为实际值，其轴承衰退时间如表1所示。

表1 轴承健康指标

Table 1 Bearing health index

衰退时间 t/min	健康指标 y	衰退时间 t/min	健康指标 y
5 050	0.03	7 550	0.58
5 300	4.40×10^{-3}	7 800	0.51
5 550	0.14	8 050	0.42
5 800	0.22	8 300	0.50
6 050	0.30	8 550	0.65
6 300	0.36	8 800	0.67
6 550	0.39	9 050	0.64
6 800	0.49	9 300	0.67
7 050	0.50	9 550	0.71
7 300	0.59	9 800	0.73

将上述观测点作为y_i，设$M=20$代入式(9)，输入至改良后的PSO算法进行迭代计算，最后计算得到的各项参数如表2所示。

将a,b,c,d所得数据代入式(8)作为理论值，其拟合曲线与实际曲线的对比如图7所示。

表2　双指数模型参数

Table 2　Parameters of the double exponential model

参数项目	a	b	c	d
参数值	0.247 657	1.09×10^{-4}	−97.41	-1.05×10^{-3}

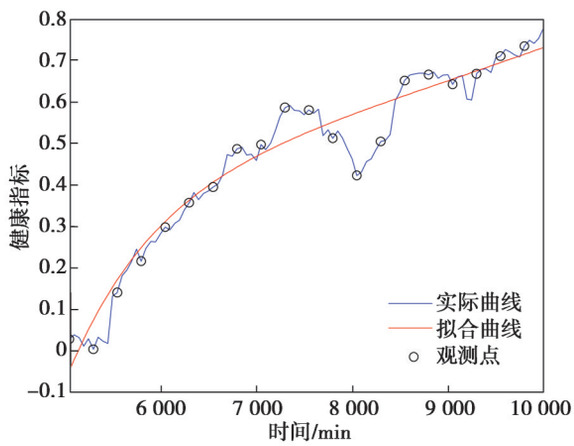


图7　拟合曲线与实际曲线对比图

Fig. 7　Comparison diagram of fitting curve and actual curve

从图7可以看出，采用改良后的PSO优化算法得到的双指数模型的参数估计拟合曲线与实际曲线误差较小，并且存在明显的单调性，拟合精度高，曲线优化好，有效地避免了PSO优化算法易早熟收敛至局部最优、迭代后期收敛速度慢，从而导致拟合双指数模型参数出现较大误差的缺点。

4.2　轴承剩余寿命预测

剩余寿命预测即预测轴承性能指标到达阈值的时间与当前时刻的时间差，主要任务是基于当前测量数据预测轴箱轴承未来的退化行为，掌握性能退化过程。计算t_k时刻轴箱轴承的剩余寿命的公式为

$$T_{\mathrm{RUL}}=t_{\mathrm{EOL}}-t_k \tag{10}$$

式中：t_{EOL}为轴承失效时刻。

由图6可知，该轴承在5 500 min时刻出现早期故障，在10 000 min时刻达到完全失效，将该时刻的健康指标设置为阈值$k=0.779$，选取5 500~6 200 min内15个健康指标点作为观测值，如表3所示。将观测值代入PSO优化模型中进行剩余寿命预测，已知在6 200 min时刻，轴承的剩余寿命为3 800 min，最后得到轴承剩余寿命曲线如图8所示。

从图8可以看出，改良后的PSO优化模型的拟合曲线预测精度较高，其性能退化曲线与实际轴承退化情况较为接近，但95%置信区间分布范围较大，这与轴承实际性能退化过程的复杂性有一定关系。通过式(10)可以计算出6 200 min时刻的理论剩余寿命为3 830 min，与实际情况的3 800 min相差30 min，误差率为0.79%，准确率较高；95%置信区间为2 900~4 200 min，跨度较大，但实际剩余寿命也在95%的置信区间内，可以认为本文所提出的方法可以较好地预测轴承剩余寿命。

表3　试验5 500~6 200 min轴承健康指标值

Table 3　Bearing health index values during 5 500~6 200 min of test

衰退时间 t/min	健康指标 y	衰退时间 t/min	健康指标 y
5 500	0.10	5 900	0.22
5 550	0.10	5 950	0.24
5 600	0.14	6 000	0.25
5 650	0.15	6 050	0.26
5 700	0.18	6 100	0.26
5 750	0.21	6 150	0.27
5 800	0.18	6 200	0.28
5 850	0.21		

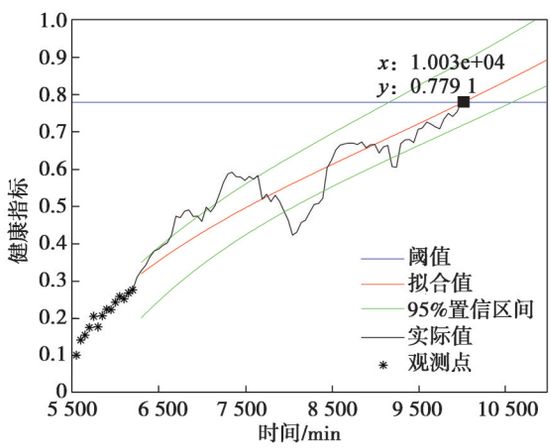


图8　6 200 min时刻预测的轴承性能退化趋势

Fig. 8　Trend bearing performance degradation predicted at 6 200 min

5　结论

本文提出了一种基于优化Bray-Curtis相异度和PSO算法的轴承退化规律及寿命预测方法，并通过轴承台架试验对比验证了所提出的轴承健康指标方法的有效性和准确性。通过输入轴承健康状态下的时域指标，训练提取出轴承的健康状态特征参数；然后，将实际所测轴承的不同试验数据输入到稀疏自编码器中，获取实际轴承健康状态特征，再计算2种不同状态下的Bray-Curtis相异度差值作为健康指标；最后，基于PSO优化算法的双指数退化模型参数估计算法验证实测的轴承振动数据，结果表明：

①基于稀疏自编码提取得到的健康指标具有客观性，有效降低了实际线路中噪声和轮轨激励对轴承振动信号的影响，可以较好地反映轴承的退化情况，并且对轴承早期故障更为敏感，可以快速、精确地确定早期故障起始点，以及轴承各退化阶段的分布情况。结合Bray-Curtis相异度差值的计算可以将轴承数据中的正常状态剔除，保留从早期故障开始到完全退化阶段的有效数据，相较于其他传统方法的健康指标可以更好找出早期故障起始点，为后续计算退化模型参数

和轴承剩余寿命提供理论支撑。

②基于改良 PSO 优化算法所建立的双指数退化模型拟合结果与实际的轴承退化规律较为一致，拟合曲线精度更高，分析相关试验数据验证了所提出的改进方法有较高的准确率，能够较为精确地揭示轴承的退化规律，可有效精确地预测轴承剩余寿命。

参考文献：

[1] 聂晔. 动车组转向架轴承可靠性分析与故障诊断的技术研究[D]. 长沙: 中南大学, 2011.
NIE Ye. Technical research on reliability analysis and fault diagnosis of EMU bogie bearing[D]. Changsha: Central South University, 2011.

[2] 王久健, 杨绍普, 刘永强, 等. 一种基于空间卷积长短时记忆神经网络的轴承剩余寿命预测方法[J]. 机械工程学报, 2021, 57(21): 88-95.
WANG Jiujian, YANG Shaopu, LIU Yongqiang, et al. A method of bearing remaining useful life estimation based on convolutional long short-term memory neural network[J]. Journal of Mechanical Engineering, 2021, 57(21): 88-95.

[3] LI Zan, WANG Fengming, WANG Chengjie, et al. Reliability modeling and evaluation of lifetime delayed degradation process with nondestructive testing[J]. Reliability Engineering & System Safety, 2021, 208: 107358.

[4] LUNDBERG G, PALMGREN A. Dynamic capacity of rolling bearings[J]. Journal of Applied Mechanics, 1949, 16(2): 165-172.

[5] ZHANG Jianxun, DU Dangbo, SI Xiaosheng, et al. Prognostics based on stochastic degradation process: the last exit time perspective[J]. IEEE Transactions on Reliability, 2021, 70(3): 1158-1176.

[6] WANG Biao, LEI Yaguo, LI Naipeng, et al. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings[J]. IEEE Transactions on Reliability, 2020, 69(1): 401-412.

[7] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.

[8] CHEN Longting, XU Guanghua, ZHANG Sicong, et al. Health indicator construction of machinery based on end-to-end trainable convolution recurrent neural networks[J]. Journal of Manufacturing Systems, 2020, 54: 1-11.

[9] YANG Hanbo, SUN Zheng, JIANG Gedong, et al. Remaining useful life prediction for machinery by establishing scaled-corrected health indicators[J]. Measurement, 2020, 163: 108035.

[10] 耿自林. 动车组轴箱轴承剩余寿命预测方法研究[D]. 成都: 西南交通大学, 2020.
GENG Zilin. Research on prediction method of residual life of axle box bearing of EMU[D]. Chengdu: Southwest Jiaotong University, 2020.

[11] 盛兆顺, 尹琦岭. 设备状态监测与故障诊断技术及应用[M]. 北京: 化学工业出版社, 2003: 21-77.
SHENG Zhaoshun, YIN Qiling. Technology and application of equipment condition monitoring and fault diagnosis[M]. Beijing: Chemical Industry Press, 2003: 21-77.

[12] KARACAY T, AKTURK N. Experimental diagnostics of ball bearings using statistical and spectral methods[J]. Tribology International, 2009, 42(6): 836-843.

[13] 卓鹏程, 严瑾, 郑美妹, 等. 面向滚动轴承全生命周期故障诊断的 GA-OIHF Elman 神经网络算法[J]. 上海交通大学学报, 2021, 55(10): 1255-1262.
ZHUO Pengcheng, YAN Jin, ZHENG Meimei, et al. GA-OIHF Elman neural network algorithm for fault diagnosis of full life cycle of rolling bearing[J]. Journal of Shanghai Jiaotong University, 2021, 55(10): 1255-1262.

[14] 范韫. 基于 EMD 距离的稀疏自编码器[J]. 计算机工程与科学, 2022, 44(5): 894-900.
FAN Yun. Sparse autoencoder based on earth mover distance [J]. Computer Engineering & Science, 2022, 44(5): 894-900.

[15] 张志敏, 柴变芳, 李文斌. 基于稀疏自编码器的属性网络嵌入算法[J]. 计算机工程, 2020, 46(7): 98-103.
ZHANG Zhimin, CHAI Bianfang, LI Wenbin. Attribute network embedding algorithm based on sparse auto-encoder[J]. Computer Engineering, 2020, 46(7): 98-103.

[16] 赵志宏, 李乐豪, 杨绍普, 等. 一种无监督的轴承健康指标及早期故障检测方法[J]. 中国机械工程, 2022, 33(10): 1234-1243.
ZHAO Zhihong, LI Lehao, YANG Shaopu, et al. An unsupervised bearing health indicator and early fault detection method[J]. China Mechanical Engineering, 2022, 33(10): 1234-1243.

[17] JIN Xiaohang, SUN Yi, QUE Zijun, et al. Anomaly detection and fault prognosis for bearings[J]. IEEE Transactions on Instrumentation and Measurement, 2016, 65(9): 2046-2054.

[18] ZHAO Bin, WANG Gang, SONG Jingyan, et al. Optimal design method of the LCLC resonant converter based on particle-swarm-optimization algorithm[J]. Journal of Electronics & Information Technology, 2021, 43(6): 1622-1629.

收稿日期：2023-04-14