基于小波包和 BP 网络的滚动轴承状态寿命模型

苗学问 洪 杰 马艳红

(北京航空航天大学 能源与动力工程学院, 北京 100191)

摘 要: 使用状态寿命(即状态良好、初始损伤、故障发展和即将失效 4 个寿命阶段)描述滚动轴承的使用寿命,并建立了滚动轴承状态寿命的评估模型. 状态寿命评估模型建模的关键是振动信号的特征提取和状态的识别算法. 针对滚动轴承振动的特点,根据小波包变换能将信号按任意时频分辨率分解到不同频段的特性,提取小波包重构信号的频带能量构造特征矢量,利用推广性能良好的贝叶斯正则化 BP 网络作为状态寿命评估的算法建立特征向量与状态寿命之间的映射,采用滚动轴承全寿命试验数据作为学习样本,训练和确定评估模型. 试验验证了模型的有效性和可信性.

关 键 词: 航空、航天推进系统; 滚动轴承; 状态寿命; 小波包变换; BP 算法; 数学模型

中图分类号: TB 114

文献标识码: A **文 章 编 号**: 1001-5965(2009)10-1161-05

Grade-life model based on wavelet package and BP network for rolling bearing

Miao Xuewen Hong Jie Ma Yanhong

(School of Jet Propulsion, Beijing University of Aeronautics and Astronautics, Beijing 100191, China)

Abstract: Grade-life was used to describe rolling bearing's service life, which means the entire service life is divided into four stages: good bearing condition, initial defect condition, damaged bearing condition and failure coming condition, and an assessment model was presented for bearing's Grade-life. Signal feature extraction and pattern recognition algorithm are keys to construct the model. Vibration signals of the rolling bearing were analyzed, and the wavelet packet analysis theory was adopted to extract the Grade-life characteristics. Through signal decomposition and single reconfiguration with wavelet package to extract feature in every frequency bands effectively, and energy of various frequency bands acting as the life feature vector was input into the improved BP neural network to realize the mapping between the Grade-life vector and the Grade-life of rolling bearing, and the model in establishing the identification model by using bearing test stand run-to-failure data as learning samples was employed. The validity and creditability of model has been demonstrated by bearing test stand dates.

Key words: aerospace propulsion system; roller bearings; Grade-life; wavelet packet transform; BP algorithm; model

滚动轴承是航空发动机转子系统广泛使用的一种支承,其运行状态直接影响整台动力装置的性能和安全. 目前实行严格的飞行小时数控制以保证主轴承的状态,这种方法的本质是基于使用寿命的统计学估计进行定时维修以确保它们在失效前被替换下来. 但是,由于疲劳损伤发展的随机

收稿日期: 2008-09-27

基金项目: 航空科学基金资助项目(2007ZB51021)

作者简介: 苗学问(1977—),男,河南周口人,博士生,xwmiao77@sohu.com.

性、载荷的不确定性及失效模式的多样性，使得主轴承使用寿命的分散度很大. 因而，当前的使用寿命模型因为例行检查和更换，对正常工况下的发动机进行不必要的维修而造成浪费；而且也不能完全避免异常交变的工况下因主轴承突然失效所造成的事故.

因此，针对主轴承的特点，发展一种可靠的使用寿命模型对提高航空发动机的可靠性、安全性和经济性必将起到关键作用. 基于此，基于振动分析，把滚动轴承的使用寿命分为状态良好、初始损伤、故障发展和即将失效4个寿命阶段(即状态寿命)，并建立了滚动轴承状态寿命的评估模型.

状态寿命评估模型建模的关键是振动信号的特征提取和状态的识别算法. 通常选择时域统计参数提取滚动轴承的振动信号特征，例如，文献[1]选择均方根值和峭度作为特征向量. 但是时域统计参数对强背景噪声环境下的特征提取灵敏性较差. 文献[2－4]选择故障特征频率的振幅作为特征向量. 但是，由于制造装配误差、转速不稳等因素的影响，轴承的实际特征频率在一个小范围内波动甚至有一个跳跃，这使得选择特征频率幅值进行特征的自动提取较为困难. 针对上述问题，考虑到①滚动轴承状态改变，其振动信号的频谱结构就发生改变，表现为振动在各个频段范围的能量分布发生改变；②即使轴承特征频率在一定范围内波动，但其观测信号的主要成分必然位于小波包满尺度分解下的一个或几个时频分辨空间中. 基于上述认识，本文提出基于小波包能量的特征提取算法，将振动信号进行满尺度正交小波分解，通过分析振动信号在小波包某一分解层次上不同时频分辨空间中的能量分布，进行滚动轴承运行状态的特征提取. 振动信号特征与轴承的状态之间没有明确的对应关系，而是需要利用采集的数据分析、判别. 考虑到神经网络建模可以不依赖于模型的结构形式而具有极强的非线性映射能力、网络的知识规则是由训练样本训练后存储在网络权系数中以及适合在线监测等优势[5－6]，本文利用正则化BP网络作为辨识算法建立滚动轴承状态寿命的评估模型.

1 状态寿命

目前，滚动轴承的寿命是指轴承开始运转后，在内、外环或滚动体上任何部分，因材料疲劳而产生破坏前，轴承转动的总圈数或小时数[7]. 滚动轴承的使用寿命受载荷，润滑，使用维护，装配，运转时间以及疲劳扩展的随机性等多种因素的影响而分散度很大. 基于时间的寿命描述方法不适合对轴承个体使用寿命的预测[5]，图1定性描述了滚动轴承的状态与运转时间的关系. 另外，航空发动机主轴承的使用特点，要求不但要关心其是否有缺陷，还关注其缺陷的程度及处置措施. 因此，基于振动分析，使用状态寿命GL(Grade-life)描述滚动轴承的使用寿命.

定义1 在不同时刻测量或计算的轴承性能变量为状态寿命特征向量 $\boldsymbol{X}$(简称特征向量).

$$\boldsymbol{X}(\boldsymbol{x}_1,\boldsymbol{x}_2,\cdots,\boldsymbol{x}_n) \quad i=1,2,\cdots,n \tag{1}$$

特征向量 $\boldsymbol{x}_i$ 可以是测定的轴承的时域统计量、小波包频段能量以及声发射信号等等.

定义2 性能变量的界限 $\boldsymbol{H}_j$ 称为轴承状态寿命界限.

$$\boldsymbol{H}_j(h_1,h_2,\cdots,h_i) \quad i=1,2,\cdots,n \quad j=1,2,3 \tag{2}$$

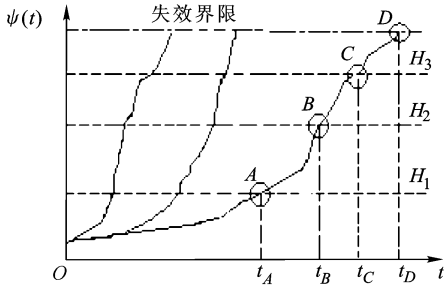


图1 状态寿命示意图

如果有一个状态变量超过了某一状态阶段的相应的状态界限，滚动轴承的寿命就进入了相应的状态寿命阶段. 比如说振动的峰值因子超过6，则意味着轴承出现了初始缺陷，状态寿命为2. 准确的确定各个状态寿命阶段的界限面临诸多困难. 因此，本文确定状态寿命阶段的界限的方法是综合运用多种技术进行振动信号特征提取，分析确定滚动轴承的状态寿命阶段：滚动轴承没有缺陷特征时，状态寿命为1；当滚动轴承出现缺陷特征时(例如出现缺陷特征频率或者某一个状态寿命特征参数发生变化等)，状态寿命为2；状态参数发生突变时，状态寿命为3；特征参数急剧增加，轴承即将失效，状态寿命为4. 显然，状态寿命是对滚动轴承的缺陷严重程度的评估.

定义3 特征向量 $\boldsymbol{X}$ 所表征的滚动轴承的状态为状态函数 $\psi(\boldsymbol{X},t)$.

$$\psi(\boldsymbol{X},t)=\boldsymbol{G}(\boldsymbol{X}) \tag{3}$$

滚动轴承特征向量(振动信号特征)与状态函数(轴承的状态)之间存在复杂的非线性映射关系 $\boldsymbol{G}$. 滚动轴承状态寿命模型的实质就是对特征向量建模辨识确定该映射关系.

2　小波包能量特征提取

在小波包分析中,由一个标准正交化的尺度函数 $\varphi(t)$通过双尺度差分方程:

$$\left.\begin{aligned} w_{2n}(t) &= \sqrt{2}\sum_{k\in Z} h_k w_n(2t-k) \\ w_{2n+1}(t) &= \sqrt{2}\sum_{k\in Z} g_k w_n(2t-k) \end{aligned}\right\} \tag{4}$$

生成函数组$\{w_{n,j,k}(t)=2^{-j/2}w_n(2^{-j}t-k)\}_{n\in Z}$称为关于$\varphi(t)$的正交小波包,其中 $w_0(t)=\varphi(t)$,$\{h_k\}_{k\in Z}$和$\{g_k\}_{k\in Z}$是由 $\varphi(t)$导出的一对共轭正交滤波器系数.

离散正交小波包变换定义为 $x(t)$在正交小波包基$\{w_{n,j,k}(t)\}_{n\in Z}$上的投影系数,即

$$p(n,j,k)=\int_{-\infty}^{+\infty} x(t)[2^{-j/2}\,\overline{w_n}(2^{-j}t-k)]\mathrm{d}t \tag{5}$$

式中,$\{p(n,j,k)\}_{k\in Z}$为 $x(t)$在正交小波包空间 U_j^n 上的小波包变换系数序列,采用式(4)得到

$$\left.\begin{aligned} p(2n,j,k) &= \sum_{l\in Z} h_{l-2k}\cdot p(n,j-1,l) \\ p(2n+1,j,k) &= \sum_{l\in Z} g_{l-2k}\cdot p(n,j-1,l) \end{aligned}\right\} \tag{6}$$

在满足 Heisenberg 测不准原理下,小波包分析能将信号 $x(t)$按任意的时频分辨率分解到不同频段,并将信号 $x(t)$的时频成分相应的投影到所代表不同频段的正交小波包空间 U_j^n 上,其中

$$U_j^n=\mathrm{Span}\{w_{n,j,k}(t),j\in Z,k\in Z\} \tag{7}$$

并且

$$\left.\begin{aligned} U_j^{2n} &\perp U_j^{2n+1} \\ U_{j-1}^n &= U_j^{2n}\oplus U_j^{2n+1} \end{aligned}\right\} \tag{8}$$

小波包空间的这种完整性和正交性使得信号 U_j^n 经过小波包变换后信息量完整,这为分析信号特征尤其是能量分布特征提供了条件.

在小波包的任意分解层次 j 上,$x(t)$在每一分解层次上的正交小波包空间投影分量代表信号 $x(t)$在对应时频分辨空间的时频局域信息. 若计算出每一个分解层次上每个小波包空间中信号分布的能量,则可将这些能量按小波包空间 U_j^n 频率指标 n 的顺序排列就构成了信号 $x(t)$的特征向量. 对于滚动轴承的非平稳振动信号,它所包含的频谱分布与滚动轴承的特征结构、缺陷的程度密切相关,因此,振动信号经小波包分解后在某一层次上不同正交小波包空间上的能量分布如同滚动轴承的故障特征频率谱一样,是滚动轴承状态的本质特征. 定义小波包空间能量算子 $E(j,n)$:

$$E(j,n)=\sum_{k\in Z}[p(n,j,k)]^2 \tag{9}$$

假设对原始信号 $x(t)$进行了 J 层小波包分解,则信号 $x(t)$在分解层次 J 上的无量纲化处理后的能量分布特征向量

$$\boldsymbol{X}=[E(J,0)/E,E(J,1)/E,\cdots,E(J,2^J-1)/E] \tag{10}$$

式中,$E=\sum_{i=0}^{2^J-1}E(J,i)$ 为信号总能量.

在实际使用中为了有效降低小波包能量特征维数,根据需要选择合适的 J 使得滚动轴承元件的故障特征频率与其他干扰振动信号分解到不同的频段上即可.

3　改进的 BP 神经网络

如图 2 所示,BP 网络模型学习的目标是实现从输入到输出的高度非线性映射的估计:

$$\hat{\psi}_{\mathrm{ot}}=G(\boldsymbol{X})=\sum_{m=1}^{M}\boldsymbol{W}_m f\left(\sum_{j=1}^{N} w_{mj}x_{\mathrm{it}-j}\right) \tag{11}$$

式中,G 是模型所要估计的未知非线性映射;$f(x)$为激励函数,通常使用 sigmoid 函数. 通过对训练样本的学习,可得对期望输出 ψ_{t} 的估计 $\hat{\psi}_{\mathrm{ot}}$.

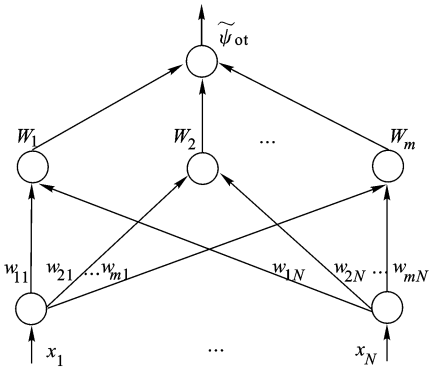


图 2　3 层 BP 神经网络模型的结构

学习过程中 BP 网络的权值 $\boldsymbol{W}_m$,w_{mj} 将被调整,目标是使误差准则函数 E 最小:

$$E=\frac{1}{2}\sum_{p=1}^{l}(\psi_p-\hat{\psi}_p)^2 \tag{12}$$

为了提高网络的推广能力,要防止网络的权重系数过大,采用正则化方法,网络的性能函数改为

$$E_{\mathrm{reg}}=\gamma\cdot E+(1-\gamma)\cdot M \tag{13}$$

式中,E_{reg}为网络的正则化性能函数;E 为网络训练误差的准则函数;M 为网络所有权值平方和的平均值;γ 为比例系数.

BP 网络学习算法采用梯度下降法:

$$w_{ji}(k+1)=w_{ji}(k)-\eta\cdot\frac{\partial E_{\mathrm{reg}}(k)}{\partial w_{ji}(k)} \tag{14}$$

式中，η 为学习速率.

4 状态寿命评估模型

以小波包频带能量为特征向量，基于贝叶斯正则化 BP 网络建立滚动轴承状态寿命的评估模型.

4.1 模型的算法设计

如图 3 所示，建模算法的实现步骤如下：

1）确定滚动轴承运行的状态寿命类型集 $s=$｛状态良好，初步损伤，故障发展，即将失效｝；相应的状态寿命标识函数值 $f=\{1,2,3,4\}$. 采集滚动轴承的全寿命试验信号，构造组成标准信号样本集.

2）对标准信号样本，首先进行时域预处理，主要是进行零均值化、滑动平滑处理以及剔除“野点”，用以消除测试误差和白噪声干扰等因素的影响，然后提取小波包频带能量分布构造状态寿命特征向量.

3）以特征向量作为 BP 模型的输入数据，与之相对应的状态寿命标识函数值作为模型的训练输出，对神经网络模型进行训练，确定模型的结构，执行流程如图 3 上半部分所示.

4）通过传感器实测振动信号，基于小波包分析提取频带振动能量分布特征，作为步骤 3）训练完毕的 BP 模型的输入数据，此时模型的对应输出即为当前滚动轴承运行状态寿命的标识函数值，执行流程如图 3 下半部分所示.

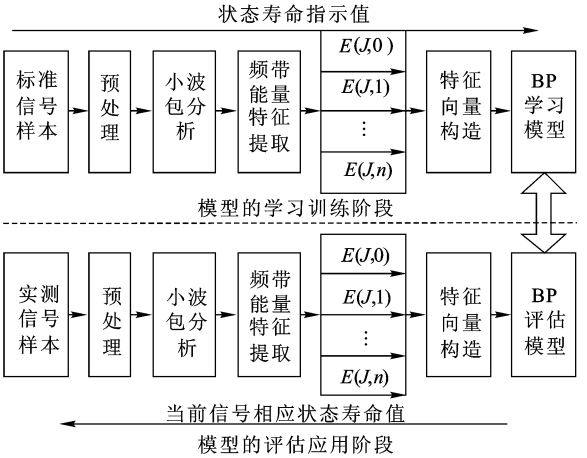


图 3 状态寿命评估模型实现流程

4.2 状态寿命评估模型训练及模型结构的确定

采用多组 6008 轴承的全寿命试验数据构成标准训练样本，标准样本的状态寿命阶段根据本文第 1 节中的方法确定. 试验时轴承的当量动载荷为 8 kN，转速设定为 3 310 r/min；振动信号的采样频率为 25 520 Hz，采用连续在线采样与存储.

基于 BP 网络建模，需要确定合适的网络结构.

1）根据 6008 轴承的参数，可计算出理论故障特征频率：滚动体为 183.6 Hz，内圈为 379.7 Hz，外圈为 282.3 Hz，采用 db5 小波对振动信号进行 3 层小波包分析，以保证轴承的故障特征频率都落在小波包分解信号的第 1 频段内. 因此，BP 网络输入层为特征向量，有 8 个参数；输出为滚动轴承的状态函数 ψ.

2）考虑到 3 层 BP 网络已经具有逼近任意非线性函数的能力，选用它作为基本辨识模型.

3）对于如何确定合适的网络隐含层结点数，本文的方法是通过数值试验确定：①把标准样本集分成训练样本集和测试样本集；②给定多个隐含层结点数不同的网络，用训练样本进行模型的学习，测试样本输入到训练完成的 BP 模型检验其推广能力，对比模型的输出与期望值，选择训练精度好且推广性能最优的网络所对应的隐含层结点数作为评估模型的隐含层结点数. 为了实现网络计算误差的均一性，本文对每一组全寿命试验数据每间隔 20 min 和 30 min 取 1 s 的采样数据构造训练样本集和测试样本集. 使用上述方法，确定隐层结点数为 7 的贝叶斯正则化 BP 网络的性能最优.

以一组轴承（称为 1＃轴承）的全寿命试验数据对确定了结构的网络进行训练和测试性能检验，结果如图 4 和图 5 所示.

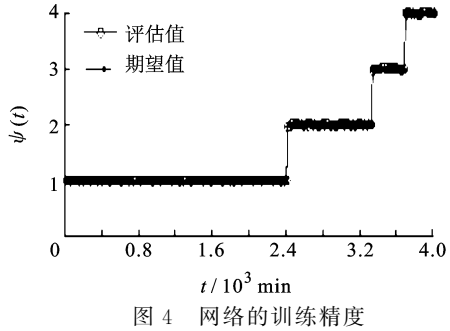


图 4 网络的训练精度

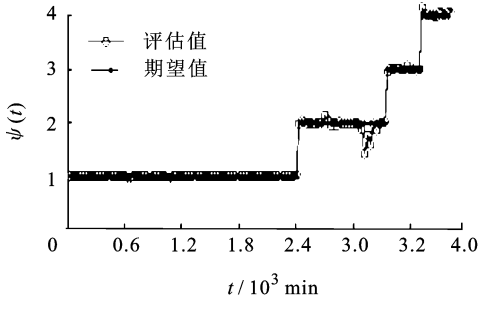


图 5 测试样本的推广性能测试

从图 4 和图 5 可以看出,无论从对训练样本的逼近精度,还是对测试样本的检验效果,该模型均具有较高的准确性和可信性.

5　应用实例

5.1　实 例 1

使用训练好的评估模型,对预置微初始缺陷轴承的寿命数据样本进行评估,结果如图 6 所示.可以看出,在评估模型当前的知识规则下(通过训练后存储在网络权系数中),所评估轴承的状态寿命为 2,即该轴承存在初始缺陷.

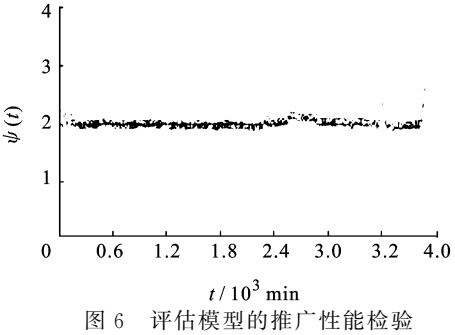


图 6　评估模型的推广性能检验

以峭度值为例对轴承振动信号进行分析,如图 7 所示.其峭度在 3.4～3.7 之间,说明轴承振动信号中冲击成分.本例说明对类同失效模式轴承,状态评估的结果具有可信性和有效性.

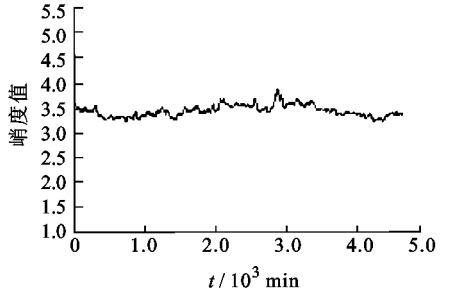


图 7　轴承振动信号的峭度值

5.2　实 例 2

对不同失效模式的轴承进行评估时,评估失败.网络进行再学习之后的测试结果如图 8 所示.从图 8 可以看出,网络通过权系数的修正对新的特征具备了良好的辨识能力.这说明 BP 网络模型良好的适应性.

对比图 8 和图 5 可以看出,在同样的试验条件下,由于损伤发展的随机性,滚动轴承使用寿命的分散度很大,传统的基于时间的使用寿命描述既不能保证安全,又可能造成浪费.状态寿命以滚动轴承“健康状况”为目标,能更好的描述其使用寿命.

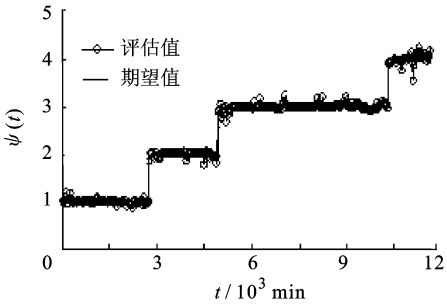


图 8　评估模型的再学习能力

6　结　论

航空发动机主轴承载荷复杂、失效模式多样和使用寿命分散度大,基于服役时间(累积循环数)的使用寿命描述方法即造成了浪费,又不能完全保证飞行安全,针对这一工程问题,本文以“状态寿命”描述主轴承的使用寿命,并基于振动分析建立了滚动轴承状态寿命的智能评估模型.本文的研究为主轴承使用寿命的预兆与管理提供一种新的途径与方法.

参考文献(References)

[1] Williams T, Ribadeneira X, Billingto S. Rolling element bearing diagnostics in run-to-failure life time testing [J]. Mechanical Systems and Signal Processing, 2001,15(5): 979－993

[2] Lawley M, Liu R, Parmeshwaran V. Residual life predictions from vibration-based degradation signals: a neural network approach [J], IEEE Transactions on Industrial Electronics, 2004, 51(3): 694－699

[3] Orsagh R, Roemer M, Sheldon J, et al. A comprehensive prognostic approach for predicting gas turbine engine bearing life[C]// Proceedings of ASME Turbo Expo. Vienna, Austria:[s. n.],2004:1－9

[4] Roemer M J, Byington C S. Prognostics and health management software for gas turbine engine bearings [C] //Proceedings of GT2007 ASME Turbo Expo, Montreal. Canada:[s. n.],2007: 14－17

[5] Shao Y, Nezu K. Prognosis of remaining bearing life using neural networks[J]. Proc Instn Mech Engrs,2000,214(1): 217－231

[6] Huang Runqing, Xia Lifeng, Li Xinglin, et al. Residual life predictions for ball bearings based on self-organizing map and back propagation neural network methods[J]. Mechanical Systems and Signal Processing, 2007(21):193－207

[7] Harris T. Rolling bearing analysis[M]. New York: John Wiley & Sons,2001

(编　辑:张　嵘)