基于GA优化BP算法的滑油状态监测

周 良[1],王华伟[1],许珊珊[2],王清薇[1]
(1.南京航空航天大学 民航学院,南京 211100;2.山东师范大学 公共管理学院,济南 250300)

摘要:滑油状态的监测与分析是航空发动机状态监测与故障诊断的重要手段。为了解决以往滑油金属质量分数预测模型算法的局部性、收敛速度慢及预测结果误差大等问题,结合遗传算法(GA)收敛速度快、鲁棒性好等优点,对反向传播(BP)神经网络算法进行GA优化,通过GA对参数寻优,并应用于发动机滑油金属质量分数预测。由于滑油的状态参数并不能确定部件故障与否,利用贝叶斯(Bayes)决策规则对诊断结果进行了错误率计算。将所提方法应用于某航空发动机滑油铁质量分数预测,结果表明:采用GA优化后的BP神经网络(GA-BP)得到的预测结果具有更高的精度,其最大预测误差不超过6%,平均预测误差为1.7%,所测数据与原数据具有较好的拟合性,利用Bayes决策规则对诊断结果进行分析,对于部件故障与否的判别更具说服力。

关键词:滑油状态;故障诊断;神经网络;遗传算法;可靠性;航空发动机

中图分类号: V228.2 **文献标识码**:A **doi**:10.13477/j.cnki.aeroengine.2022.05.015

Lubricating Oil Condition Monitoring Based on Genetic Algorithm Optimized Back Propagation Algorithm

ZHOU Liang[1],WANG Hua-wei[1],XU Shan-shan[2],WANG Qing-wei[1]
(1. College of Civil Aviation,Nanjing University of Aeronautics and Astronautics,Nanjing 211100, China; 2 .School of Public Administration,Shandong Normal University,Jinan 250300,China)

Abstract:Lubricating oil condition monitoring and analysis is an important means of aeroengine condition monitoring and fault diagnosis. In order to solve the problems of previously proposed prediction algorithms for the metal mass fraction of lubricating oil as local in optimization,slow in convergence,large prediction error,etc., a Genetic Algorithm (GA) optimized Back Propagation (BP) neural network algorithm was proposed. Taking advantages GA's fast convergence and robustness, the BP algorithm was optimized through GA parameter optimization and was applied to the prediction of metal mass fraction of engine lubricating oil. Because the state parameters of lubricating oil are unable to be used to determine whether the component is faulty or not,Bayesian decision rules were used to calculate the error rate of diagnosis. The proposed method was applied to predict the mass fraction of lubricating iron in an aeroengine. The results show that the BP neural network optimized by GA is more accurate for the prediction. The maximum prediction error is less than 6%,and the average prediction error is 1.7%. The measured data fit well with the original data. Diagnosis result analyzed using Bayes decision rules is more convincing in judging whether the component is faulty or not.

Key words:lubricating oil condition;fault diagnosis;neural network;genetic algorithm;reliability;aeroengine

0 引言

滑油系统是航空发动机的重要组成部分,由于滑油的循环利用特点,其携带了大量的发动机内部信息。滑油监测技术是通过分析润滑油的性能变化和携带的磨粒,获得发动机摩擦学系统的润滑和磨损状态信息,以此评价发动机的工况和状态,并确定故障原因、类型。因此,滑油状态监测是航空发动机健康监测和故障诊断的重要手段[1-3]。通过对滑油中金属含量的预测,可监测发动机轴承、齿轮等重要部件的健康状态[4],并及时维修或更换,以保障飞行安全和降低运营成本[5-7]。

研究人员在以滑油状态监测实现航空发动机健康监测[8-9]和故障诊断[10-11]方面进行了大量研究。修

收稿日期:2020-07-03 **基金项目**:国家自然科学基金(U1833110)资助
作者简介:周良(1996),男,在读硕士研究生,研究方向为交通运输工程(适航技术与管理);E-mail:1243729063@qq.com。

引用格式:*周良,王华伟,许珊珊,等. 基于GA优化BP算法的滑油状态监测[J].航空发动机,2022,48(5):137-142. ZHOU Liang,WANG Huawei,XU Shanshan,et al. Lubricating oil condition monitoring based on genetic algorithm optimized back propagation algorithm[J]. Aeroengine,2022,48(5):137-142.*

攀瑞等[12]综合运用多种滑油分析技术，有效监测了发动机传动润滑系统的磨损状态，及时发现磨损故障并确定了故障部位；马敏等[13]提出一种基于多尺度卷积神经网络、长短期记忆网络和反向传播（Back propagation,BP）网络的单通道网络模型用于滑油监测数据的特征提取，该方法以串行方式提取数据在空间维度和时间维度上的2维特征，提高了数据样本的分类精度；曹宏庆[14]以数学方法和智能算法相结合，挖掘滑油磨粒携带的信息，提高发动机滑油颗粒监测试验的科学性和准确性；陈庆贵等[15]利用径向基（Radial Basis Function，RBF）过程神经网络预测航空发动机滑油金属含量，对比单一BP网络，具有更高的预测精度，但未对RBF网络的收敛速度和迭代过程作详细对比阐述，使预测结果缺少一定说服力；曾力等[16]利用支持向量回归机（Support Vector Regression，SVR）模型对滑油金属含量进行预测，模型易向全局最优靠拢，提高了收敛速度，但试验数据较少，在一定程度上，预测结果的准确度不稳定；Lopez等[17]制订了一种传感器解决方案，可在线监测滑油的降解状况，可定性地进行滑油理化性能分析，但无法实现发动机故障预测和健康管理。

针对以往算法容易陷入局部最优，收敛速度慢，鲁棒性差以及预测精度不高等问题，本文提出一种GA-BP算法框架，将遗传算法（Genetic Algorith,GA）用于BP网络，利用GA寻找全局最优权值和阈值，并进行BP网络的训练。

1 GA优化BP模型

1.1 模型框架

GA优化BP神经网络分为BP神经网络结构确定、GA优化和BP神经网络预测3部分。其中，BP神经网络结构确定部分根据拟合函数输入、输出参数数目确定BP神经网络结构，可以确定GA优化参数数目，进而确定GA个体的编码长度。BP神经网络用GA得到的最优个体对网络进行初始权值和阈值的赋值，网络经训练后预测样本输出。GA优化BP模型如图1所示。

根据BP网络模型，权值数为100×150+150×60+60×2=24120，阈值数为：150+60+2=212，所需优化参数的数目为：24120+212=24332。此过程是利用GA优化权值和阈值，替代BP神经网络反向传播的过程。

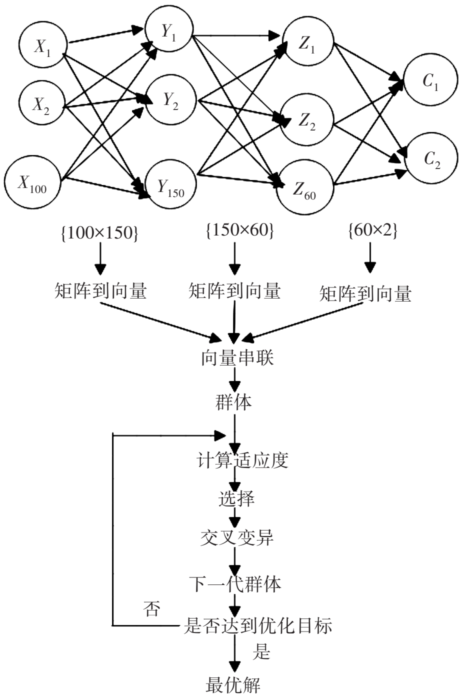

图1 GA优化BP模型

1.2 BP网络模型

BP网络[18-19]工作的基本原理实质上是通过对网络权值(ω_{ij},T_{ij})的修正和阈值θ的修正，使误差函数E沿负梯度方向降低，并使得最终误差在允许的范围内。这里选取1个3层的神经网络，即2个隐藏层，1个输出层。BP网络模型如图2所示。

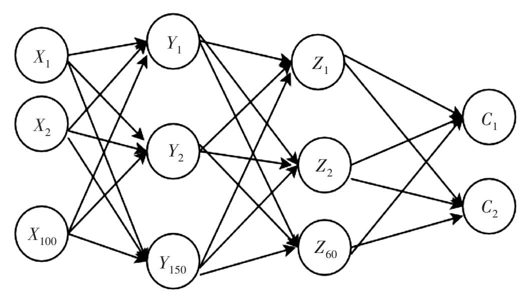

图2 BP网络模型

输入节点为X_i，隐藏层节点分别设为Y_j,Z_k，输出节点为C_m，连接输入节点与隐藏层节点之间的权值和阈值设为$\omega_{(1)ij}$，$\theta_{(1)j}$，隐层节点之间的权值和阈值设为$\omega_{(2)jk}$，$\theta_{(2)k}$，隐藏层和输出层之间的权值和阈值设为$\omega_{(3)km}$，$\theta_{(3)m}$。

1.3 GA模型

GA模型[20]通过模拟生物界自然选择和自然遗传机制的进化过程，采用自然选择、遗传、变异等作用机制，得到适应度最高的个体。GA算法在解决大空间、

多峰值、非线性和全局优化等问题上具有显著优势[21-22]。GA模型如图3所示。

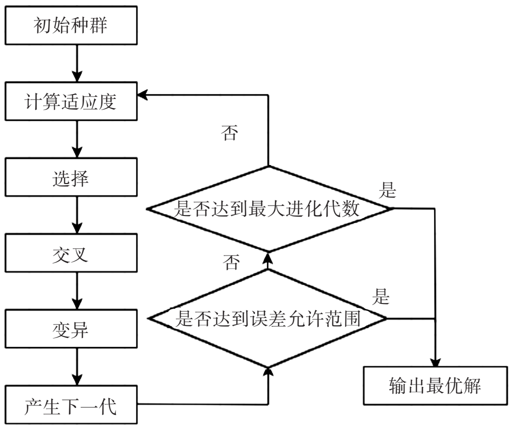

图3　GA模型

2　GA优化BP算法原理

2.1　算法流程

GA优化BP网络算法流程如图4所示。

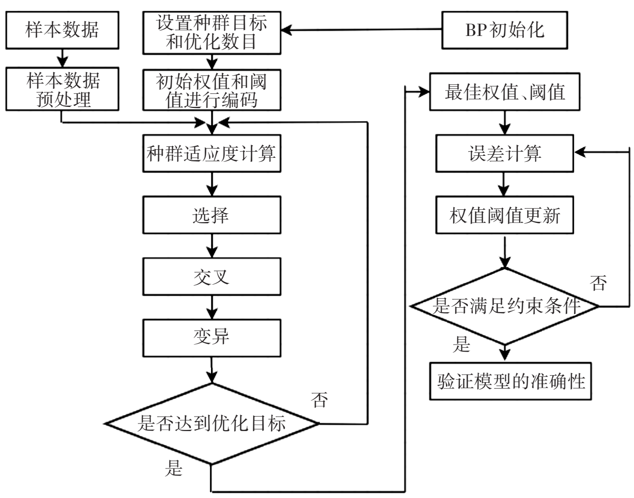

图4　GA优化BP网络算法流程

2.2　BP神经网络算法

(1)对于隐层节点Y_j来说,其计算输出为

$$Y_j=f_1(\Sigma\omega_{(1)ij}X_i-\theta_{(1)j})=f_1(e_j)$$

$$e_j=\Sigma\omega_{(1)ij}X_i-\theta_{(1)j} \tag{1}$$

(2)对于隐层节点Z_k,其计算输出为

$$Z_k=f_2(\Sigma\omega_{(2)jk}Y_j-\theta_{(2)k})=f_2(e_k)$$

$$e_k=\Sigma\omega_{(2)jk}Y_j-\theta_{(2)k} \tag{2}$$

(3)输出节点的计算输出为

$$C_m=f_3(\Sigma\omega_{(3)km}Z_k-\theta_{(3)m})=f_3(e_m)$$

$$e_m=\Sigma_k\omega_{(3)km}Z_k-\theta_{(3)m} \tag{3}$$

(4)若输出节点的期望输出设为O_m时,则输出节点的误差为

$$E=\frac{1}{2}\Sigma_m(O_m-C_m)^2=\delta_{(3)m} \tag{4}$$

(5)权值修正

$$\omega^1_{(3)km}=\omega_{(3)km}+\Delta\omega_{(3)km}=\omega_{(3)km}+\eta\delta_{(3)m}Z_k \tag{5}$$

同理可得到$\omega^1_{(2)jk}$,$\omega^1_{(1)ij}$。

(6)阈值修正

$$\theta^1_{(3)m}=\theta_{(3)m}+\eta\delta_{(3)m} \tag{6}$$

同理可得到$\theta^1_{(2)k}$,$\theta^1_{(1)j}$。

2.3　GA算法

(1)此算法最终目的是得到误差最小的权值和阈值,因此,目标函数为最小化问题,可写为

$$f(x)=O_m-C_m \tag{7}$$

(2)适应度函数为

$$\mathrm{Fit}(f(x))=\frac{1}{1+c+f(x)}$$

$$c\geqslant0,c+f(x)\geqslant0 \tag{8}$$

式中:Fit为适应度函数;c为常数。

(3)编码。假如参数的取值范围为$[U_{\min},U_{\max}]$,用长度为λ的二进制的编码符号串来表示该参数,那么一共可产生2^λ种不同的编码,以δ表示二进制编码的精度

$$\delta=\frac{U_{\max}-U_{\min}}{2^\lambda-1} \tag{9}$$

(4)解码。假设个体的编码是$x:b_\lambda b_{\lambda-1}\cdots b_1$,那么对应的解码公式为

$$x=U_{\min}+\left(\sum_{i=\lambda}^{1}b_i\cdot2^{i-1}\right)\cdot\frac{U_{\max}-U_{\min}}{2^\lambda-1} \tag{10}$$

(5)选择。设第t代种群$A(t)$中所能匹配的样本数为m,记为$m(H,t)$。设第1代中群体大小为n,则第$t+1$代中样本数为

$$m(H,t+1)=m(H,t)n\frac{f(H)}{\Sigma_i f_i} \tag{11}$$

式中:$f(H)$为平均适应度;f_i为个体适应度。

(6)交叉。假设2个个体X_A,X_B之间进行交叉,则交叉运算后所产生的2个新个体为

$$X_A'=\alpha X_B+(1-\alpha)X_A,X_B'=\alpha X_A+(1-\alpha)X_B \tag{12}$$

式中:α为参数,若为常数,则可称为均匀算术交叉,若α为变量,则此时的交叉运算可称为非均匀算术交叉。

在交叉后模式H的生存概率为P_s,遭到破坏的概率为P_d,发生交叉的概率为P_c,故H生存的概率为

$$P_s=1-\frac{\delta(H)}{t-1}=1-P_cP_d=1-\frac{P_c\delta(H)}{m-1} \tag{13}$$

（7）变异。设串的某一位置发生改变的概率为P_m，那么，不变的概率为$1-P_m$，当$P_m<<1$时，模式H在变异作用下生存概率为

$$P_s=(1-P_m)^{o(H)} \tag{14}$$

式中：$o(H)$为模式H的阶数。

2.4 Bayes决策

状态空间可设置为$\Omega=(\omega_1,\omega_2,\cdots,\omega_m)$，在状态监测中，主要判断工况故障与否，先验概率用$P(\omega_1)$、$P(\omega_2)$表示，$p(x|\omega_1)$为正常状态的条件概率密度函数，$p(x|\omega_2)$为故障状态的密度函数，$P(\omega_i|x)$表示已知样本条件下$\omega_i$出现的概率。

（1）对2类状态有

$$P(\omega_i|x)=\frac{p(x|\omega_i)P(\omega_i)}{\sum_{i=1}^{2}p(x|\omega_i)P(\omega_i)} \tag{15}$$

（2）决策规则

$$P(\omega_i|x)>P(\omega_j|x),x\in\omega_i \tag{16}$$

（3）错误率计算

$$\varepsilon=P(e)=\int_{-\infty}^{+\infty}P(e|x)p(x)\,\mathrm{d}x \tag{17}$$

（4）由式（3）~（16）可知，$P(\omega_i|x)>P(\omega_i|x)$，决策$\omega_i$，在此决策下，错误概率$P(\omega_i|x)$为

$$P(e|x)=P(\omega_j|x),P(\omega_j|x)<P(\omega_i|x) \tag{18}$$

3 算例

数据来源于某型号通用航空发动机从一次换油到另一次换油完整工作阶段的滑油光谱分析数据。在滑油的监测过程中，以铁的质量为主要的监测对象。从滑油光谱数据中得到铁的质量时间序列数据共161个，如图5所示。

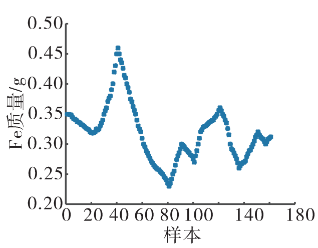

图5 铁的质量时间序列

以前140个数据作为网络的训练样本，最后21组数据作为网络的测试样本，用MatLab测试算法的性能，分别用GA-BP算法模型、RBF网络、SVR模型和BP网络对滑油铁的质量时间序列进行预测，并对各算法模型预测结果进行对比，以分析各算法模型的精确度和可靠性。

3.1 GA-BP模型预测结果分析

在此算法下，网络结构设为1-7-1，网络的误差精度设为1×10^{-5}，迭代次数为100。则铁的质量的预测输出和期望输出如图6所示。GA优化BP预测结果误差如图7所示。

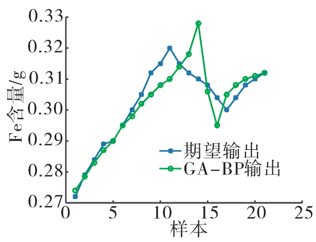

图6 GA优化BP的铁的质量预测输出和期望输出

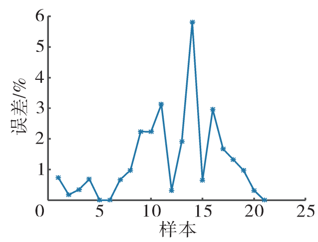

图7 GA优化BP预测结果误差

从图6中可见，GA-BP预测数据与样本数据较为吻合，且预测数据曲线与样本数据曲线趋势一致。从图7中可见，GA-BP预测数据误差百分比最大不超过6%，预测精度较高，误差在可接受范围之内。

3.2 算法模型输出结果分析

分别利用RBF网络、SVR模型和BP网络对样本数据进行预测，并将各种算法模型的预测结果与GA-BP模型预测输出进行对比分析。算法模型预测结果如图8所示。各种算法模型预测结果误差对比如图9所示。

从图8中可见，与其他模型算法相比，GA-BP预测结果曲线与原数据的拟合度最高，RBF和SVR模型对预测结果都有较高的精度，BP网络在后期数据的预测中未收敛。从图9中可见，在相同训练样本的情况下，GA-BP预测误差相对处于较低水平，其预测精度优于其它模型算法。

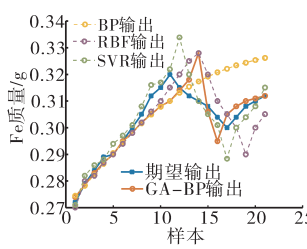

图8 各种算法模型预测结果对比

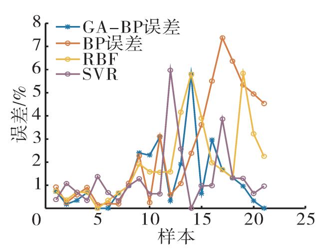

图9 算法模型预测结果误差对比

从图8、9中可见，各算法模型前期预测数据精度较高，在样本数据出现转折时，算法模型预测数据都出现了不同程度的误差，体现出算法模型在滑油金属质量时间序列预测问题上的不稳定性。因此，为了更直观展现后期各算法模型性能，将后期各种算法模型预测误差数据进行整合，见表1。

表1　各种算法模型预测误差　　　　%

模型	序列											平均误差
	11	12	13	14	15	16	17	18	19	20	21	
GA-BP	3.1	0.3	1.9	5.8	0.6	2.9	1.6	1.3	0.9	0.3	0	1.7
RBF	1.7	1.6	4.2	5.8	3.9	2.0	1.7	1.3	5.8	3.2	2.2	3.0
SVR	0.6	6.0	2.6	0	1.0	1.0	3.9	1.3	1.3	0.6	1.0	1.8
BP	3.1	0.6	1.1	2.4	3.7	5.5	7.4	6.4	5.4	5.0	4.5	5.3

从表中可见,GA-BP模型平均误差最小,与其他模型算法相比,其预测误差普遍偏小,在可控范围内平稳波动。

3.3　结果分析

从上述试验结果中可得,GA-BP无论是预测精度还是收敛速度都优于其它模型算法的,GA-BP网络在样本数据出现转折时,其预测误差轻微波动,但与样本数据的拟合度较高,整体误差不超过6%,平均误差为1.7%,在可控范围之内,预测精度和收敛速度较为优异,在寻优的问题上有较好的适用性。

3.4　Bayes分析

Bayes分析主要用于判断发动机工况正常和异常2种状态,以ω_1、ω_2表示,先验概率用$P(\omega_1)$、$P(\omega_2)$表示,且有$P(\omega_1)+P(\omega_2)=1$,设$P(\omega_1)=a$,则$P(\omega_2)=1-a$,以$x$表示某测点滑油中金属的质量分数,为了使诊断结果更具有说服力,引用悲观决策准则的思想,在滑油时间序列的测试结果中取误差最大的时刻(即第17个样本点)为本次测点,在此处滑油预测中金属质量分数$x=0.322$,则在正常状态下的条件概率密度函数为$p(x=0.322|\omega_1)$,可设$p(x=0.322|\omega_1)=A$,同理,在异常状态下的条件概率密度函数为$p(x=0.322|\omega_2)=B$,A和B可看作关于x的一次函数。

由式(15)可得各状态下概率函数为

$$p(\omega_1|x=0.322)=\frac{A\cdot a}{A\cdot a+B(1-a)}$$

$$p(\omega_2|x=0.322)=\frac{B(1-a)}{A\cdot a+B(1-a)}$$

由式(17)计算错误率

$$\varepsilon=P(e)=\int_{-\infty}^{0.322}B\cdot(1-a)\,\mathrm{d}x+\int_{0.322}^{+\infty}A\cdot a\,\mathrm{d}x$$

由概率密度函数可得决策错误率图像,如图10所示。

由决策错误率图像分析可知,在预测结果误差最大时,决策错误率最大。为使决策错误率最小,在$x<0.322$时,决策ω_1即为正常状态;当$x>0.322$时,决策ω_2即为异常状态。即Bayes决策规则就是对每个x都使得$P(e)$最小,也就是错误率最小。

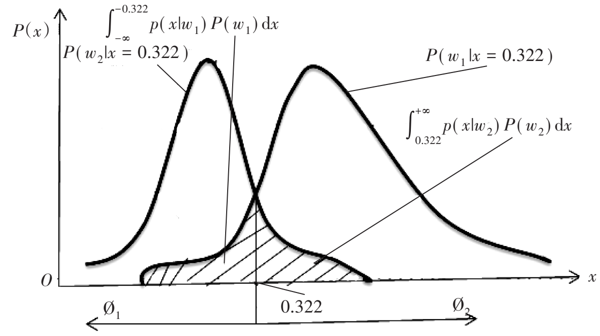

图10　决策错误率图像

4　结论

(1)结合GA算法收敛速度快、鲁棒性好、泛化能力高等优点,对BP网络进行GA优化,构建了GA-BP网络模型,提高了原有BP网络的预测性能;

(2)以某型通用航空发动机滑油金属质量分数数据为例,GA-BP模型预测数据整体误差小于6%,平均误差小于1.7%,相比单一BP网络和其他算法,GA优化后的BP网络预测数据精度高,收敛速度快,训练时间短,预测结果更具可靠性;

(3)通过Bayes对诊断结果分析,当滑油金属质量分数小于0.322时,决策为正常状态,此时诊断错误率较低,提高了诊断结果的可靠度,为基于滑油状态监测对航空发动机重要部件的健康状况进行判别提供了更为全面有效的方法。

参考文献:

[1] 何振林,刘安林,王登辉,等. 滑油监测技术在设备磨损检测中的应用研究[J]. 机械,2020,47(5):23-26.
HE Zhenlin, LIU Anlin, WANG Denghui, et al. Study on oil analysis technology and its application in the detection of mechanical wear[J]. Machinery,2020,47(5):23-26. (in Chinese)

[2] Du Ying, Wu T H, Zhou S X, et al. Remaining useful life prediction of lubricating oil with dynamic principal component analysis and proportional hazards model[J]. Journal of Engineering Tribology, 2020, 234(6):964-971.

[3] Zhang Y, Cao Y, Si E W, et al. Study on a high sensitive online sensor for wear particles in lubricant[J]. Journal of Physics: Conference Series,2019, 1237(4):42082.

[4] Henneberg M, Jørgensen B, Eriksen R L. Oil condition monitoring of gears onboard ships using a regression approach for multivariate T2 control charts[J]. Journal of Process Control,2016,46:1-10.

[5] 万洋. 某型航空发动机滑油金属屑末在线检测系统研制[D]. 广汉:中国民用航空飞行学院,2019.

WAN Yang. Development of on-line detection system for a certain type of aero-engine oil metal debris[D]. Guanghan: Civil Aviation Flight University of China, 2019. (in Chinese)

[6] Wang M M, Ge Q B, Jiang H Y, et al. Wear fault diagnosis of aeroengines based on broad learning system and ensemble learning[J]. Energie, 2019, 12(24): 47-50.

[7] 艾延廷，王克明，沙云东. 航空发动机状态监测与故障诊断技术[M]. 北京：北京理工大学出版社，2017：223-233.

AI Yanting, WANG Keming, SHA Yundong. Aeroengine condition monitoring and fault diagnosis technology[M]. Beijing: Beijing Institute of Technology Press, 2017: 223-233. (in Chinese)

[8] 苏泽盛，王星州. 基于ABC-BP神经网络的航空发动机滑油金属含量预测[J]. 北华航天工业学院学报，2019，29(2)：9-11.

SU Zesheng, WANG Xingzhou. Prediction of metal content in aero-engine lubricating oil based on ABC-BP neural network[J]. Journal of North China Institute of Aeronautics and Astronautics, 2019, 29(2): 9-11. (in Chinese)

[9] 胡文杰. 航空发动机滑油颗粒荷电及其注入装置研究[D]. 南昌：南昌航空大学，2017.

HU Wenjie. The research on particles charging and injection device of aeroengine lubricating oil system[D]. Nanchang: Nanchang Hangkong University, 2017. (in Chinese)

[10] 莫凡臣. 航空发动机滑油箱油量实时测量的方法研究[D]. 沈阳：沈阳航空航天大学，2015.

MO Fanchen. Research on aero-engine lubricating oil real-time measurement method[D]. Shenyang: Shenyang Aerospace University, 2015. (in Chinese)

[11] Kumar P, Hirani H, Agrawal A K. Online condition monitoring of misaligned meshing gears using wear debris and oil quality sensors[J]. Industrial Lubrication and Tribology, 2018, 70(4): 645-655.

[12] 修攀瑞，佟文伟，郎宏，等. 滑油分析技术在发动机磨损状态监测中的应用[J]. 山东化工，2015，44(16)：138-140，144.

XIU Panrui, TONG Wenwei, LANG Hong, et al. The application of lubricant analysis technology in wear condition monitoring of aero-engine[J]. Shandong Chemical Industry, 2015, 44(16): 138-140, 144. (in Chinese)

[13] 马敏，王涛，王力. 基于深度学习的滑油监测方法研究[J]. 推进技术，2020，41(5)：1159-1167.

MA Min, WANG Tao, WANG Li. Research on monitoring method of lubricating oil based on deep learning[J]. Journal of Propulsion Technology, 2020, 41(5): 1159-1167. (in Chinese)

[14] 曹宏庆. 某型发动机滑油颗粒监测试验研究[D]. 南京：南京航空航天大学，2012.

CAO Hongqing. Research on experiments of aero-engine lubricating oil debris monitoring[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2012. (in Chinese)

[15] 陈庆贵，于光辉，谢静，等. 基于神经网络的航空发动机滑油金属含量预测[J]. 兵器装备工程学报，2019，40(12)：150-152，209.

CHEN Qinggui, YU Guanghui, XIE Jing, et al. Prediction of aeroengine lubricating oil metal content based on neural networks[J]. Chinese Journal of Ordnance Equipment Engineering, 2019, 40(12): 150-152, 209. (in Chinese)

[16] 曾力，龙伟. 基于SVR的航空发动机滑油金属含量预测方法[J]. 四川大学学报（工程科学版），2016，48(增刊2)：161-164.

ZENG Li, LONG Wei. Prediction method of metal content of aero-engine lubricating oil based on SVR [J]. Journal of Sichuan University (Engineering Science Edition), 2016, 48(S2): 161-164. (in Chinese)

[17] Lopez P, Mabe J, Miró G, et al. Low cost photonics sensor for in-line oil quality monitoring: methodological development process towards uncertainty mitigation[J]. Sensors, 2018, 18(7): 2015.

[18] 张东. BP神经网络算法的技术分析[J]. 软件，2016，37(12)：227-229.

ZHANG Dong. Technical analysis of BP neural network algorithm[J]. Software, 2016, 37(12): 227-229. (in Chinese)

[19] Liu P F, Zhang W. A fault diagnosis intelligent algorithm based on improved BP neural network[J]. International Journal of Pattern Recognition and Artificial Intelligence, 2019, 33(9): 19.

[20] 李岩，袁弘宇，于佳乔. 遗传算法在优化问题中的应用综述[J]. 山东工业技术，2019(12)：242-243，180.

LI Yan, YUAN Hongyu, YU Jiaqiao. Summary of application of genetic algorithms in optimization problems[J]. Shandong Industrial Technology, 2019(12): 242-243, 180. (in Chinese)

[21] 周林，赵杰，冯广飞. 装备故障预测与健康管理技术[M]. 北京：国防工业出版社，2015：129-137.

ZHOU Lin, ZHAO Jie, FENG Guangfei. Equipment failure prediction-al health management technology[M]. Beijing: National Defense Industry Press, 2015: 129-137. (in Chinese)

[22] 王铁方. 基于家族基因的网格信任模型[M]. 北京：知识产权出版社，2016：135-147.

WANG Tiefang. Grid trust model based on family genes[M]. Beijing: Intellectual Property Press, 2016: 135-147. (in Chinese)

（编辑：刘　亮）