

基于改进灰色神经网络的故障预测方法研究*

杨森, 孟晨, 王成

(军械工程学院 导弹工程系, 石家庄 050003)

摘要: 故障预测技术是电子装备预测与健康管理(PHM)领域的核心内容,对电子装备关键部件实施有效的预测是保证系统正常运行的关键。首先将灰色理论和人工神经网络算法相结合,构建灰色神经网络模型并对其进行分析;然后在此基础上通过附加动量变学习速率法对灰色神经网络的权值更新策略进行改进,提出一种基于改进灰色神经网络的故障预测模型;最后以某型脉冲测量雷达中频接收组合中的压控振荡器为例,以采集的原始频率数据为基础进行仿真验证。预测结果表明,将该预测方法应用于电子装备 PHM 是行之有效的,可有效提高故障预测精度。

关键词: 故障预测; 预测与健康管理; 灰色神经网络模型; 附加动量变学习速率法; 改进灰色神经网络

中图分类号: TP206; TP277 **文献标志码:** A **文章编号:** 1001-3695(2013)12-3625-04

doi:10.3969/j.issn.1001-3695.2013.12.028

Research on method of fault prediction based on improved grey neural network

YANG Sen, MENG Chen, WANG Cheng

(Dept. of Missile Engineering, Ordnance Engineering College, Shijiazhuang 050003, China)

Abstract: Fault prediction technology is the core content of electronic equipment PHM, carrying out effective prediction on the key components of electronic equipment is the guarantee of system running in normal operation. Firstly, this paper built and analyzed the general grey neural network model by combining grey theory and artificial neural network. Then improved the weight updating strategy of grey neural network by the method of additional momentum and variable learning rate, and put forward a fault prediction method based on improved grey neural network model. Finally, it took a voltage controlled oscillator (VCO) of the intermediate frequency combination in a certain pulse instrumentation radar as an example, and the collected original frequency data as the basis to simulate. The results show that applying the prediction method to electronic equipment PHM can effectively improve the fault prediction accuracy.

Key words: fault prediction; prognostic and health management (PHM); grey neural network model; additional momentum and variable learning rate method; improved grey neural network

随着计算机信息技术的不断发展和进步,装备正朝着高度复杂化、集成化和微型化的方向发展,装备性能的不断提以及系统复杂性的不断增加,使得装备的可靠性与维修保障等问题越来越突出。在我军装备跨越式发展过程中,电子装备在武器系统中的比重越来越大,其健康状态的优劣对武器系统的整体性能有着至关重要的影响。因此,为了减少由于电子装备故障引发的严重后果,降低维修保障费用,提高部队战斗力,电子装备的健康问题越来越引起我军的高度重视^[1,2]。

PHM 技术是美军方率先提出的一种以状态维修为基础的全新的视情维修策略,主要包括数据采集、数据处理、状态监测与评估、故障预测和维修决策等关键技术^[3,4]。其中,故障预测技术是 PHM 理论有别于传统故障诊断理论的显著特征之一,也是近年来装备健康管理领域的一个热点研究问题。

针对电子装备的电路特点,目前电子装备 PHM 中不同的故障预测研究方法主要有三种^[5,6]:a) 基于保险和预警装置的方法;b) 基于故障预兆监控与推理的方法;c) 基于失效物理(physics of failure, PoF)模型的方法。其中,基于故障预兆监控与推理的方法不需要系统的先验知识(数学模型和专家知

识),以历史数据为基础,针对即将到来的故障显示出一种数据事件或趋势,并通过数据处理算法进行趋势预测,是目前应用较为广泛的预测方法。该方法主要包括基于时间序列分析的预测模型、基于灰色理论的预测模型、基于人工神经网络的预测模型^[7,8]等。

考虑到电子装备故障样本获取困难、健康状态信息不全、以及历史数据大多呈现非线性关系等特点,本文将适用于小样本、贫信息的灰色理论和具有较强非线性映射能力的人工神经网络算法相结合,在分析基本灰色神经网络模型的基础上,采用附加动量变学习速率法对网络权值更新策略进行改进,提出一种基于改进灰色神经网络的故障预测模型。仿真结果表明,同灰色模型和灰色神经网络模型相比,该模型具有更高的预测精度,非常适用于电子装备的故障预测。

1 灰色神经网络模型分析

1.1 灰色模型

灰色模型是指对灰色不确定性系统行为特征的发展变化

收稿日期: 2013-03-04; **修回日期:** 2013-04-17 **基金项目:** 国家“十一五”装备预先研究项目(51317030104);国家自然科学基金资助项目(60771063)

作者简介: 杨森(1984-),男,河北石家庄人,博士,主要研究方向为自动测试与故障诊断、预测与健康管理等(yangsanmu@sogou.com);孟晨(1963-),男,教授,博士,主要研究方向为复杂电子装备自动测试与故障诊断、故障预测与信息融合、信号处理等。

进行预测的模型,简称 GM (grey model) 模型。该模型以原始数据序列为基础建立微分方程,利用系统信息,使得抽象模型被量化,进而在缺乏系统特征知识的情况下预测系统输出^[9,10]。模型描述如下:

设原始数据序列 $x^{(0)}$ 为

$$x^{(0)} = (x^{(0)}(t) | t=1, 2, \dots, n) = (x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)) \quad (1)$$

对 $x^{(0)}$ 作一次累加得到新的数据序列 $x^{(1)}$, 新的数据序列 $x^{(1)}$ 的第 t 项为原始数据序列 $x^{(0)}$ 的前 t 项之和,即

$$x^{(1)} = (x^{(1)}(t) | t=1, 2, \dots, n) = (x^{(0)}(1), \sum_{i=1}^2 x^{(0)}(i), \sum_{i=1}^3 x^{(0)}(i), \dots, \sum_{i=1}^n x^{(0)}(i)) \quad (2)$$

设 $z^{(1)}$ 为 $x^{(1)}$ 的紧邻均值生成序列,即

$$z^{(1)}(t) = 0.5[x^{(1)}(t) + x^{(1)}(t-1)] \quad t=2, 3, \dots, n \quad (3)$$

该序列称为白化背景值序列,每一个白化背景值 $z^{(1)}(t)$ 均为 $x^{(1)}(t)$ 和 $x^{(1)}(t-1)$ 的平均值。根据新的数据序列 $x^{(1)}$ 建立灰微分方程,即

$$\frac{dx^{(1)}}{dt} + ax^{(1)} = b \quad (4)$$

采用最小二乘法估计 a 和 b 的值:

$$\begin{bmatrix} a \\ b \end{bmatrix} = [B^T B]^{-1} B^T Y \quad (5)$$

其中:

$$B = \begin{bmatrix} -z^{(1)}(2) & 1 \\ -z^{(1)}(3) & 1 \\ \vdots & \vdots \\ -z^{(1)}(n) & 1 \end{bmatrix}, Y = \begin{bmatrix} x^{(0)}(2) \\ x^{(0)}(3) \\ \vdots \\ x^{(0)}(n) \end{bmatrix} \quad (6)$$

则该方程的解为

$$x_{t+1}^{*(1)} = (x_1^{(0)} - \frac{b}{a})e^{-at} + \frac{b}{a} \quad t=1, 2, \dots, n \quad (7)$$

$x_{t+1}^{*(1)}$ 为 $x_{t+1}^{(1)}$ 序列的估计值,对 $x_{t+1}^{*(1)}$ 作一次累减得到 $x^{(0)}$ 的预测值 $x_{t+1}^{*(0)}$, 即

$$x_{t+1}^{*(0)} = x_{t+1}^{*(1)} - x_t^{*(1)} \quad t=1, 2, \dots, n \quad (8)$$

1.2 灰色神经网络模型分析

灰色神经网络模型就是通过将灰色理论与神经网络算法相结合,对不确定性问题进行求解的模型^[11]。其基本思路为: a) 将灰微分方程式(4)的解映射到一个 BP (back propagation) 神经网络之中; b) 采用已知样本序列对该神经网络进行训练,获得相应的微分方程系数 a 和 b ,进而得到白化后的灰微分方程; c) 利用该微分方程对未知样本序列进行预测。

将灰色模型中灰微分方程的解作为灰色神经网络的时间响应函数,记为

$$y(t) = (x_1^{(0)} - \frac{b}{a})e^{-at} + \frac{b}{a} \quad (9)$$

假设原始序列中元素个数为 N ,若 t 对应于离散时间序列 $\{k\}$ ($k=0, 1, \dots, N-1$), 则对应式(9)的离散时间响应函数为

$$y(k) = (x_1^{(0)} - \frac{b}{a})e^{-ak} + \frac{b}{a}, k=0, 1, \dots, N-1 \quad (10)$$

对上式两边同乘以 $\frac{1}{1 + \exp(-ak)}$, 得

$$y(k) \cdot \frac{1}{1 + \exp(-ak)} = (x_1^{(0)} - \frac{b}{a}) \cdot \frac{e^{-ak}}{1 + \exp(-ak)} + \frac{b}{a} \cdot \frac{1}{1 + \exp(-ak)} \quad (11)$$

则有

$$y(k) = [(x_1^{(0)} - \frac{b}{a}) \cdot \frac{e^{-ak}}{1 + \exp(-ak)} + \frac{b}{a} \cdot \frac{1}{1 + \exp(-ak)}]$$

$$[1 + \exp(-ak)] = [(x_1^{(0)} - \frac{b}{a}) \cdot (1 - \frac{1}{1 + \exp(-ak)}) + \frac{b}{a} \cdot \frac{1}{1 + \exp(-ak)}] \cdot [1 + \exp(-ak)] = [(x_1^{(0)} - \frac{b}{a}) - x_1^{(0)} \cdot \frac{1}{1 + \exp(-ak)} + \frac{2b}{a} \cdot \frac{1}{1 + \exp(-ak)}] \cdot [1 + \exp(-ak)] \quad (12)$$

将式(12)映射到 BP 神经网络中,得到的灰色神经网络拓扑结构如图1所示。其中: k 为网络输入; $y(k)$ 为网络预测输出值; $w_{11}, w_{21}, w_{22}, w_{31}, w_{32}$ 为网络权值; θ 为输出节点的阈值; LA, LB, LC, LD 分别表示灰色神经网络的四层。

设 $u = \frac{b}{a}$, 则网络的初始权值可表示为

$$w_{11} = a, w_{21} = -x_1^{(0)}, w_{22} = 2u, w_{31} = w_{32} = 1 + \exp(-ak) \quad (13)$$

LD 层中输出节点的阈值为

$$\theta = (x_1^{(0)} - u) \cdot (1 + \exp(-ak)) \quad (14)$$

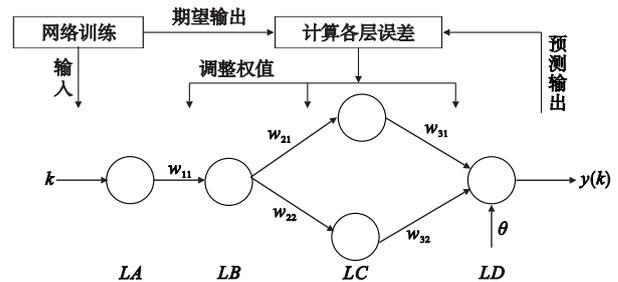


图1 灰色神经网络拓扑结构

灰色神经网络的学习主要由样本的正向传递和误差的反向传播两个过程组成。在正向传递过程中,输入样本从输入层经隐含层逐层处理,直至输出层;若输出层得不到期望输出,则转入反向传播阶段,根据预测误差调整网络权值和阈值,从而使网络的预测输出不断逼近期望输出^[12,13]。

当输入第 k 个样本时,网络第 m 层的第 j 个节点的输出为

$$\alpha_j^{m,k} = f^m(W_{ij}^m \alpha_i^{m-1,k} + b_j^m) \quad (15)$$

其中: W_{ij}^m 为第 $m-1$ 层的第 i 个神经元与第 m 层的第 j 个神经元之间的连接权值; b_j^m 为第 m 层第 j 个节点的阈值; $\alpha_j^{m,k}$ 和 $\alpha_i^{m-1,k}$ 分别表示第 k 个样本下第 m 层的第 j 个节点输出和第 $m-1$ 层的第 i 个节点输出; f^m 表示第 m 层的传递函数。本文为方便描述,当某一层的节点数为 1 时,下标 i 或 j 可省略,下同。

根据式(13)~(15)并结合图1中的网络拓扑结构,可得灰色神经网络每一层的输出为

$$LA_a = \alpha^{1,k} = k \quad (16)$$

$$LB_b = \alpha^{2,k} = \frac{1}{1 + \exp(-w_{11}k)} \quad (17)$$

$$LC_c_1 = \alpha_1^{3,k} = w_{21} \cdot \alpha^{2,k}, LC_c_2 = \alpha_2^{3,k} = w_{22} \cdot \alpha^{2,k} \quad (18)$$

$$LD_d = \alpha^{4,k} = w_{31} \cdot \alpha_1^{3,k} + w_{32} \cdot \alpha_2^{3,k} + \theta \quad (19)$$

其中, LB 层传递函数选取 S 型的 Sigmoid 函数,该函数存在一个高增益区,能确保网络最终达到稳定态。其他各层传递函数取 $f(x) = x$ 。Sigmoid 函数表达式如下^[14]:

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (20)$$

网络在第 k 个样本下的平方误差定义为

$$E(k) = \frac{1}{2}(O(k) - y(k))^2 \quad (21)$$

其中, $O(k)$ 为网络期望输出, $y(k)$ 为网络预测输出。

假设灰色神经网络的训练样本共有 K 个,则对应这 K 个训练样本的网络均方差为

$$E = \frac{1}{K} \sum_{k=1}^K E(k) \quad (22)$$

定义 $\delta_j^{m,k} = \frac{\partial E(k)}{\partial \alpha_j^{m,k}}$ 为网络在训练第 k 个样本时第 m 层第 j

个节点的误差,则网络权值的误差形式梯度计算公式为

$$\frac{\partial E(k)}{\partial W_{ij}^m} = \frac{\partial E(k)}{\partial \alpha_j^{m,k}} \cdot \frac{\partial \alpha_j^{m,k}}{\partial W_{ij}^m} = \frac{\partial E(k)}{\partial \alpha_j^{m,k}} \cdot (f^m)' \cdot \alpha_i^{m-1,k} = \delta_j^{m,k} \cdot (f^m)' \cdot \alpha_i^{m-1,k} \quad (23)$$

其中, $(f^m)'$ 表示第 m 层传递函数的导数。

假设第 $m+1$ 层有 l 个节点,则有

$$\delta_j^{m,k} = \frac{\partial E(k)}{\partial \alpha_j^{m,k}} = \sum_l \frac{\partial E(k)}{\partial \alpha_l^{m+1,k}} \cdot \frac{\partial \alpha_l^{m+1,k}}{\partial \alpha_j^{m,k}} = \sum_l \frac{\partial E(k)}{\partial \alpha_l^{m+1,k}} \cdot (f^{m+1})' \cdot W_{jl}^{m+1} \quad (24)$$

其中: $\delta_l^{m+1,k}$ 表示网络在训练第 k 个样本时第 $m+1$ 层第 l 个节点的误差; $(f^{m+1})'$ 表示第 $m+1$ 层传递函数的导数; W_{jl}^{m+1} 表示第 m 层第 j 个和第 $m+1$ 层第 l 个神经元之间的连接权值。

在网络训练过程中采用批处理方式修正网络权值和阈值,即在所有训练样本输入完成之后,通过计算总的均方误差梯度调整网络参数,该方式从全局角度出发,可以使误差函数一直向减小的方向移动。网络权值的调整公式为

$$W_{ij}^m = W_{ij}^m - \eta \cdot \frac{\partial E}{\partial W_{ij}^m} = W_{ij}^m - \eta \cdot \frac{1}{K} \cdot \sum_{k=1}^K \frac{\partial E(k)}{\partial W_{ij}^m} \quad (25)$$

其中, η 为学习速率。

根据式(23)~(25)并结合图 1 中的网络拓扑结构,计算灰色神经网络每一层的误差并根据误差调整网络权值:

LD 层误差 $\delta^4,k = y(k) - O(k)$

LC 层误差 $\delta_1^3,k = \delta_2^3,k = \delta^4,k \cdot (1 + \exp(-w_{11}k))$

LB 层误差 $\delta^2,k = w_{21} \cdot \delta_1^3,k + w_{22} \cdot \delta_2^3,k$

根据预测误差更新网络权值:

$$w_{11} = w_{11} - \eta \cdot \frac{1}{K} \cdot \sum_{k=1}^K k \cdot \delta^2,k \cdot \frac{1}{1 + \exp(-w_{11}k)} \cdot \left(1 - \frac{1}{1 + \exp(-w_{11}k)} \right)$$

$$w_{21} = -x_1^{(0)}, w_{22} = w_{22} - \eta \cdot \frac{1}{K} \cdot \sum_{k=1}^K (\delta_2^3,k \cdot \alpha^2,k)$$

$$w_{31} = w_{32} = 1 + \exp(-w_{11}k)$$

调整阈值 θ :

$$\theta = \left(x_1^{(0)} - \frac{w_{22}}{2} \right) \cdot (1 + \exp(-w_{11}k))$$

在灰色神经网络训练过程中,对网络权值 w_{11} 、 w_{21} 、 w_{22} 、 w_{31} 、 w_{32} 以及输出阈值 θ 的不断修正即为对灰参数 a 和 b 不断求解最优值的过程,模型的预测能力也在这个过程中得到不断提高,当网络均方误差 E 满足精度要求时,灰色神经网络训练结束。利用该训练好的模型即可对新的数据序列进行预测。

2 基于改进灰色神经网络的故障预测模型

灰色神经网络模型建立在灰色理论基础之上,通过神经网络的学习优化灰参数 a 与 b 的值,提高了预测精度。但是,该模型也存在不足之处^[15]: a) 灰色神经网络模型采用梯度修正法对网络权值进行调整,从网络预测误差的负梯度方向修正权值,但并未考虑以前经验的积累,导致学习过程收敛缓慢; b) 对于灰色神经网络模型而言,选择合适的学习速率也至关重要,过大的学习速率将使得权值在学习过程中产生振荡,而过小的学习速率则使得网络收敛过慢,权值难以稳定。

针对上述两点不足,本文提出基于附加动量变学习速率法的模型改进策略。在修正网络权值时,不仅考虑误差在梯度方向上的作用,而且考虑在误差曲面上变化趋势的影响,在每一个权值变化量上附加一项正比于前次权值变化量的值,并根据反向传播法产生新的权值;在网络学习过程中,学习速率 η 自适应改变,在网络进化初期 η 较大,使得网络快速收敛,随着迭代次数的增加,学习速率 η 不断减小,使得网络趋于稳定。

基于附加动量变学习速率法的网络权值调整公式为

$$\begin{cases} W_{ij}^m(p) = W_{ij}^m(p-1) - \eta(p) \cdot \frac{\partial E_p}{\partial W_{ij}^m(p)} + \alpha \Delta W_{ij}^m(p-1) \\ \eta(p) = \eta_{\max} - p(\eta_{\max} - \eta_{\min})/p_{\max} \end{cases} \quad (26)$$

其中: p 为当前迭代次数; p_{\max} 为最大迭代次数; $\Delta W_{ij}^m(p-1)$ 为第 $m-1$ 层的第 i 个神经元和第 m 层的第 j 个神经元之间的连接权值在第 $p-1$ 次迭代时的改变量; α 为动量系数, $0 \leq \alpha \leq 1$; $\eta(p)$ 为第 p 次迭代时的学习速率; η_{\max} 为最大学习速率; η_{\min} 为最小学习速率。

基于改进灰色神经网络的故障预测模型如图 2 所示。

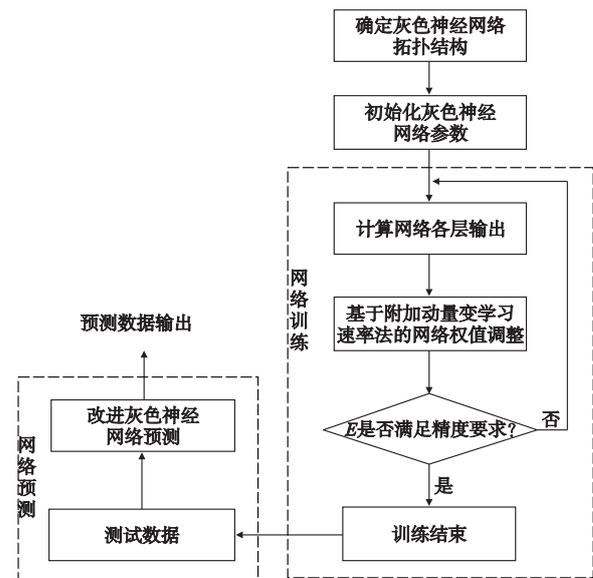


图2 基于改进灰色神经网络的故障预测模型

预测模型实现步骤如下:

- a) 确定灰色神经网络拓扑结构。采用图 1 所示的网络拓扑结构进行分析。
- b) 初始化灰色神经网络参数。初始化灰微分方程参数 a 、 b , 并利用式(13)(14)计算网络的初始权值和阈值。
- c) 灰色神经网络训练。根据式(16)~(19)计算网络各层输出,并采用式(26)的权值调整公式对网络参数进行修正,当网络均方误差 E 满足精度要求时,灰色神经网络训练结束。
- d) 灰色神经网络预测。将测试数据送入训练好的灰色神经网络模型之中进行预测,得到预测数据输出。

3 实例验证

下面以某脉冲测量雷达中频接收组合中的压控振荡器为例,验证上述模型的有效性。

压控振荡器的故障特征是渐变的,它是脉冲测量雷达中频接收组合的重要组成部分,其性能好坏直接影响雷达的正常工作。因此,为了减少由于压控振荡器故障引发的严重后果,对其进行故障预测是十分必要的。压控振荡器的正常输出为 10

MHz ± 1.8 Hz, 对其进行等间隔采样得到 60 个原始频率监测数据, 如表 1 所示。

表 1 压控振荡器原始频率监测数据

| 时刻 | 频率值/MHz | 时刻 | 频率值/MHz | 时刻 | 频率值/MHz |
|----|-----------|----|-----------|----|-----------|
| 1 | 9.9999979 | 21 | 9.9999933 | 41 | 9.9999885 |
| 2 | 9.9999989 | 22 | 9.9999942 | 42 | 9.9999893 |
| 3 | 9.9999978 | 23 | 9.9999936 | 43 | 9.9999874 |
| 4 | 9.9999988 | 24 | 9.9999941 | 44 | 9.9999889 |
| 5 | 9.9999995 | 25 | 9.9999932 | 45 | 9.9999880 |
| 6 | 9.9999988 | 26 | 9.9999929 | 46 | 9.9999860 |
| 7 | 9.9999979 | 27 | 9.9999933 | 47 | 9.9999871 |
| 8 | 9.9999976 | 28 | 9.9999924 | 48 | 9.9999865 |
| 9 | 9.9999973 | 29 | 9.9999930 | 49 | 9.9999851 |
| 10 | 9.9999975 | 30 | 9.9999920 | 50 | 9.9999842 |
| 11 | 9.9999964 | 31 | 9.9999925 | 51 | 9.9999852 |
| 12 | 9.9999969 | 32 | 9.9999923 | 52 | 9.9999831 |
| 13 | 9.9999958 | 33 | 9.9999916 | 53 | 9.9999836 |
| 14 | 9.9999964 | 34 | 9.9999918 | 54 | 9.9999842 |
| 15 | 9.9999953 | 35 | 9.9999913 | 55 | 9.9999825 |
| 16 | 9.9999959 | 36 | 9.9999910 | 56 | 9.9999831 |
| 17 | 9.9999949 | 37 | 9.9999905 | 57 | 9.9999835 |
| 18 | 9.9999953 | 38 | 9.9999901 | 58 | 9.9999824 |
| 19 | 9.9999942 | 39 | 9.9999903 | 59 | 9.9999826 |
| 20 | 9.9999944 | 40 | 9.9999895 | 60 | 9.9999805 |

选取表 1 中前 50 个数据作为训练样本训练基于改进灰色神经网络的故障预测模型, 并按照式 (26) 的权值调整公式对网络参数进行修正, 网络共学习进化 120 次, 最终得到的最佳灰色神经网络参数为 $a=0.4138, b=0.7426$ 。

利用训练好的模型对后 10 个监测数据进行预测, 预测值同实际值的比较结果如图 3 所示, 各预测方法的相对误差 ($\times 10^{-8}$) 比较如表 2 所示。

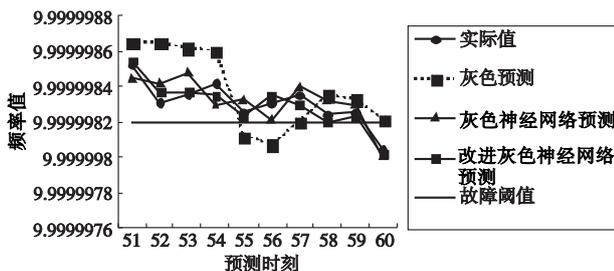


图3 预测值同实际值的比较

表 2 各预测方法相对误差 ($\times 10^{-8}$) 的比较

| 预测时刻 | 灰色 | 灰色神经网络 | 改进灰色神经网络 |
|--------|------|--------|----------|
| 51 | 1.3 | 0.7 | 0.3 |
| 52 | 3.4 | 1.1 | 0.6 |
| 53 | 2.6 | 1.2 | 0.1 |
| 54 | 1.8 | 1.2 | 0.7 |
| 55 | 1.3 | 0.8 | 0.2 |
| 56 | 2.4 | 1.0 | 0.4 |
| 57 | 1.5 | 0.5 | 0.5 |
| 58 | 1.1 | 0.8 | 0.4 |
| 59 | 0.7 | 0.4 | 0.3 |
| 60 | 1.6 | 0.5 | 0.3 |
| 平均相对误差 | 1.77 | 0.82 | 0.38 |

从图 3 和表 2 中可以看出, 基于改进灰色神经网络的故障预测方法平均相对误差明显小于灰色预测和灰色神经网络预测, 预测精度较高, 说明将该方法应用于电子装备故障预测是可行的。

4 结束语

故障预测技术是电子装备 PHM 的研究热点之一, 目前关于故障预测方法的分类尚不统一, 其中以机器学习为主的预测方法应用最为广泛。本文提出的基于改进灰色神经网络的故障预测模型以灰色理论和神经网络算法为基础, 充分考虑了灰色模型的小样本、贫信息学习特性和神经网络优良的非线性学习能力, 在构建基本灰色神经网络模型的基础上, 采用附加动量和变学习速率的方式对网络权值更新策略进行了改进, 并通过仿真实验与灰色预测、灰色神经网络预测进行比较。对比结果显示该模型能够有效利用有限的原始监测数据对网络进行训练, 预测误差很小, 有较高的预测精度, 是对电子装备进行故障预测的一条有效途径。但是, 本文在构建模型的过程中对网络参数是随机进行初始化的, 这有可能导致在网络进化过程中陷入局部最优, 进而影响预测结果的准确度。因此, 模型网络参数的初始设定以及优化问题是进一步研究的内容。

参考文献:

- [1] ANTONI J, DANIERET J, GUILLET F. Effective vibration analysis of ic engines using cyclostationarity-part I: a methodology or condition monitoring[J]. *Journal of Sound and Vibration*, 2002, 257(5): 815-837.
- [2] “十一五”通用装备保障科技信息研究成果汇编[K]. [S. l.]: 总装通用装备保障部科技信息办公室, 2011:3-13.
- [3] DISCENZO F M, NICKERSON W, MITCHELL C E, et al. Open systems architecture enables health management for next generation system monitoring and maintenance[R]. [S. l.]: OSA-CBM Development Group, 2001.
- [4] HENLEY S, CURRER R, SCHEUREN B, et al. Autonomic logistics-the support concept for the 21st century[C]//Proc of IEEE Aerospace Conference. 2000:417-421.
- [5] FILEV D P, TSENG F. Novelty detection based machine health prognostics[C]//Proc of International Symposium on Evolving Fuzzy Systems. 2006:193-199.
- [6] 郭阳明, 蔡小斌, 张宝珍, 等. 故障预测与健康状态管理技术综述[J]. *计算机测量与控制*, 2008, 16(9):1213-1216, 1219.
- [7] 王雪. 测试智能信息处理[M]. 北京: 清华大学出版社, 2008:33-56.
- [8] 彭宇, 刘大同, 彭喜元. 故障预测与健康管理技术综述[J]. *电子测量与仪器学报*, 2010, 24(1):1-9.
- [9] 邓聚龙. 灰色系统基本方法[M]. 2版. 武汉: 华中理工大学出版社, 2004:12-25.
- [10] 黄大荣, 黄丽芬. 灰色系统理论在故障预测中的应用现状及其发展趋势[J]. *火炮发射与控制学报*, 2009, 9(3):88-92.
- [11] 阳树洪, 李春贵, 夏冬雪. 基于灰色神经网络的入侵检测系统研究[J]. *计算机工程与设计*, 2007, 28(19):4622-4624.
- [12] 纪崑, 王汉林. 基于灰色神经网络的企业风险特征指标动态预测方法研究[J]. *数学的实践与认识*, 2009, 39(15):52-60.
- [13] 金瑜. 基于小波神经网络的模拟电路故障诊断方法研究[D]. 成都: 电子科技大学, 2004:22-26.
- [14] 史峰, 王小川, 郁磊, 等. MATLAB 神经网络 30 个案例分析[M]. 北京: 北京航空航天大学出版社, 2010:258-261.
- [15] 徐祥合. 基于 BP 神经网络的客户分类方法研究[D]. 南京: 南京航空航天大学, 2004:44-67.