

# 基于 BP 神经网络的卫星故障诊断方法

苏振华<sup>1</sup>, 陆文高<sup>1</sup>, 齐晶<sup>2</sup>, 薛野<sup>1</sup>, 陈逢田<sup>1</sup>

(1. 航天东方红卫星有限公司, 北京 100094; 2. 中国空间技术研究院, 北京 100094)

**摘要:** 为了有效地利用卫星下传的海量遥测数据, 在测试过程中对卫星进行实时的故障诊断, 提出了一种基于 BP 神经网络的卫星故障诊断方法; 该方法包括离线自主学习和实时在线故障诊断两部分; 离线自主学习部分基于历史数据库和更新样本进行自主学习, 学习获得神经网络模型存储于知识库; 实时在线故障诊断部分依据相应的神经网络模型, 对遥测数据进行实时在线的诊断; 为了验证基于 BP 神经网络的卫星故障诊断方法的有效性和优越性, 以现有型号三轴稳定近地卫星控制分系统为实验对象, 利用该方法对具有代表性的红外地球敏感器和动量轮的相关遥测数据进行分析; 通过将该方法的实验结果与基于 Kalman 滤波的方法的实验结果进行对比分析, 表明该方法能够有效地对卫星的故障进行诊断。

**关键词:** 卫星; BP 神经网络; 故障诊断

## A Method of Satellite Fault Diagnosis Based on BP Neural Network

Su Zhenhua<sup>1</sup>, Lu Wengao<sup>1</sup>, Qi Jing<sup>2</sup>, Xue Ye<sup>1</sup>, Chen Fengtian<sup>1</sup>

(1. DFH Satellite Co., Ltd., Beijing 100094, China 2. China Academy of Space Technology, Beijing 100094)

**Abstract:** In order to effectively use of the massive remote sensing data transmitted from satellites, in the process of testing for satellite real-time fault diagnosis, a method of satellite fault diagnosis based on BP neural network is proposed. The method includes offline autonomous learning and the real-time online fault diagnosis. The offline autonomous learning part automatically learns based on historical database and the updated samples, learning for neural network model is stored in the knowledge base. The real-time on-line fault diagnosis part is for the diagnosis of remote sensing data in real time online, based on the corresponding neural network model. To verify the method of satellite fault diagnosis based on BP neural network is effective and superior, with the control subsystem of the three axis stabilized near earth satellite as experimental object, the method is used to analysis the typical remote sensing data of infrared earth sensors and momentum wheel. By the experimental results analysis of this method and the method based on Kalman filtering, the experimental results show that the method is effective to satellite fault diagnosis.

**Keywords:** satellite; BP neural network; fault diagnosis

## 0 引言

卫星下传的遥测数据能够反映星上设备功能、性能及工作状态, 在地面综合测试过程中需要对其进行连续的监视和判读。目前, 卫星遥测数据的监视和判读主要靠人工完成, 判读分析过程有以下几个特点: 工作量非常大、需要专家的经验知识, 且海量数据判读无法完全通过人工完成。为了有效利用星上上传的遥测数据, 在测试过程中实现实时的卫星故障诊断, 利用人工智能技术实现卫星遥测数据的智能监视和判读是卫星综合测试的必然趋势<sup>[1-2]</sup>。

人工神经网络<sup>[3-4]</sup>作为一种人工智能技术, 已经广泛的应用于模式识别、信号处理及人工智能等领域。人工神经网络是一个由大量简单的处理单元(神经元)广泛连接组成的人工神经网络, 用来模拟大脑神经系统的结构和功能。它能从已知数据中自动的归纳规则, 获得这些数据的内在规律, 具有很强的非线性映射能力。BP 网络<sup>[5]</sup>作为其中有代表性的神经网络模型, 是基于 BP (back propagation) 误差反向传播算法的多层前馈神经网络。

本文在深入分析遥测数据特点的基础上, 提出了一种基于

BP 神经网络的卫星故障诊断方法。该方法包括离线自主学习子系统和实时在线故障诊断子系统两部分。离线自主学习子系统基于历史数据库和更新样本进行自主学习, 得到神经网络模型。实时在线故障诊断子系统依据相应的神经网络模型, 对遥测数据进行实时在线的诊断。

## 1 遥测数据特性分析

遥测数据随时间的变化趋势是由系统的工作、环境等条件决定的相对规律过程, 当系统工作异常导致故障发生时, 往往体现在表征系统特性的遥测信息发生变化, 这一变化是用来对卫星进行故障诊断的依据。有效识别和获取能够反映卫星设备健康状态的数据信息, 包括反映系统/分系统/单机工作状态和性能指标的参数信息等, 是进行故障诊断的必要前提。基于遥测数据实现故障诊断的基本思想, 就是通过分析遥测数据的变化特性, 有效地挖掘出其内在的意义, 实现状态感知, 得出预测评估结果<sup>[6-8]</sup>。

通过对卫星遥测数据长期变化规律的研究和分析, 将遥测数据变化特性分为 4 类: ①基本不变的遥测参数, 当设备工作正常情况下, 其温度、电压、负载电流等部分遥测参数会保持在某一恒定值或其附近区域; ②单调变化的遥测参数, 随着时间的推移, 一些参数会单调递增或递减, 如计时器、计数器、参数发散收敛趋势等; ③周期变化的遥测参数, 卫星遥测参数会按固定周期进行交变; ④状态变化的遥测参数, 以数字量为

收稿日期: 2015-11-17; 修回日期: 2016-01-04。

作者简介: 苏振华(1987-), 男, 山东, 工程师, 主要从事小卫星综合测试方向的研究。

主, 会随卫星的具体情况或单机设备的工作状态设置而变化。

在本质上, 卫星下传的遥测数据能够全面地反映卫星的内  
在特性, 这些数据中隐含着大量的有用信息。为此, 本文建立  
了一个神经网络, 让其自主进行学习, 来发掘出这些数据中隐  
藏的规律。经过训练后, 生成具有训练样本内在属性的网络  
结构。

### 2 卫星故障诊断

基于 BP 神经网络的卫星故障诊断原理图如图 1 所示, 该  
方法能够根据输入的实时下传遥测数据进行卫星故障诊断, 输  
出故障诊断的结果; 包括离线自主学习和实时在线故障诊断两  
部分。其中, 离线自主学习部分包括基于历史数据库的自主学  
习过程和基于更新样本的重新自主学习过程。通过学习得到的  
神经网络模型存储于知识库中, 利于在线模块的调用。实时在  
线故障诊断部分包括: 实时数据库、遥测数据预处理模块、遥  
测数据诊断模块; 能够依据知识库中相应的神经网络模型, 对  
遥测数据进行实时在线的诊断。

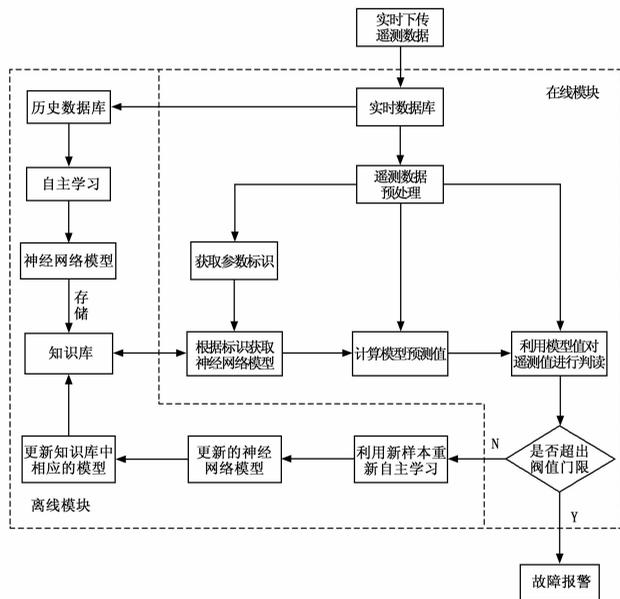


图 1 基于 BP 神经网络的卫星故障诊断原理图

#### 2.1 BP 神经网络设计

BP 神经网络是一种典型的信息前向传播、误差反向传播  
神经网络, 层与层之间互联, 各层的神经元之间相互独立, 近  
年来广泛用于数据分类和预测。其中, 最基本最典型的三层  
BP 神经网络由输入层 (input layer)、隐含层 (hidden layer)、  
输出层 (output layer) 组成, 各层之间存在连接权值, 连接权  
值的大小反映了各神经元之间的连接强度。

根据卫星遥测数据的特点, 本文设计了典型的三层 BP 神  
经网络拓扑结构如图 2 所示。在神经网络中, kolmogorov 三  
层神经网络映射存在定理在理论上证明了任意一个连续函数都  
能与一个三层 BP 网络建立映射关系<sup>[4]</sup>, 即存在一个输入层有  
 $n$  个神经元, 隐层有  $2n+1$  个神经元, 输出层有  $m$  个神经元的  
三层神经网络。经分析, 遥测参数最多有 5 个特征参数, 由此  
确定 BP 神经网络隐含层神经元的个数, 设置隐含层 11 个  
节点。

针对所诊断的遥测数据的具体特点, 选取  $n$  个具有代表性

的遥测参数构成输入层向量:  $\mathbf{A}_k = (a_1, a_2, \dots, a_n)$   
 $k = 1, 2, \dots, m, \dots$ ,  $a_i$  即为能够反映被诊断遥测数据特性  
的遥测参数; 相应地, 被诊断遥测数据作为输入层向量的期望  
输出向量为:  $\mathbf{Y}_k = (y_1, y_2, \dots, y_q)$ , 即  $q=1$ ; 隐含层单元输入  
向量为:  $\mathbf{S}_k = (s_1, s_2, \dots, s_p)$ , 隐含层单元输出向量为:  $\mathbf{B}_k =$   
 $(b_1, b_2, \dots, b_p)$ , 其中  $p$  分别对应隐含层节点数 11; 对应着期  
望输出向量, 输出层单元输入向量为:  $\mathbf{L}_k = (l_1, l_2, \dots, l_q)$ , 输  
出层单元输出向量为:  $\mathbf{C}_k = (c_1, c_2, \dots, c_q)$ , 其中  $q=1$ ; 反映  
输入层遥测参数和被诊断遥测参数之间隐藏关系的参数设置如  
下: 输入层至隐含层连接权:  $\{W_{ij}\} i=1, 2, \dots, n, j=1, 2, \dots, p$ ,  
隐含层至输出层连接权:  $\{V_{jt}\} j=1, 2, \dots, p, t=1, 2, \dots, q$ , 隐  
含层各单元输出阈值:  $\{\theta_j\} j=1, 2, \dots, p$ , 输出层各单元输出阈  
值:  $\{\gamma_t\} t=1, 2, \dots, q$ 。其中,  $m$  为学习模式对个数。

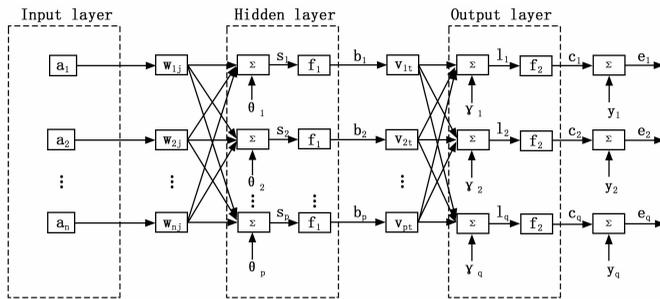


图 2 BP 神经网络拓扑结构

图中,  $f_1, f_2$  分别为隐含层和输出层的传递函数,  $W, \theta$  为隐  
含层权值和阈值,  $V, \gamma$  为输出层权值和阈值。输入层到隐含层  
传递函数和隐含层到输出层传递函数为双曲正切函数:  $f(x) =$   
 $\frac{1}{1 + e^{-x}}$ 。

#### 2.2 离线自主学习

在依据遥测数据的特性建立了合适的神经网络后, 需要通  
过离线自主学习生成具有遥测参数内在属性的网络结构。离线  
自主学习主要利用样本数据进行训练, 有效地挖掘出遥测数据  
内在的特征信息, 获得遥测数据实时在线诊断的知识。

离线自主学习的过程是一个反复迭代确定上一章节所设计  
神经网的各神经元之间权重的过程。历史数据库以训练样本所  
需的格式, 存储了大量的历史测试数据, 为自主学习提供了充  
足的样本。本文算法从历史数据库取得训练样本, 基于 BP 误  
差反向传播算法不断地调整网络的各个权值。当输入任意一  
个样本, 网络的输出误差控制在一个期望的范围之内时, 即表  
示网络的训练完成, 获得所需的网络结构。自主学习的具体过  
程如下:

- 1) 初始化所建立的 BP 神经网络模型, 给各连接权  $\{W_{ij}\}, \{V_{jt}\}$  及阈值  $\{\theta_j\}, \{\gamma_t\}$  赋予  $(-1, 1)$  间的随机值;
- 2) 从历史数据库中随机选一组相关联的样本数据组成输入向量和输出向量, 按照公式 (1) 将输入向量和输出向量  $X$  进行归一化使其在  $(-1, 1)$  之间, 然后将输入向量和输出向量提供给 BP 神经网络模型的输入层和输出层

$$x_i = \frac{x_i}{\|X\|}, \|X\| = \sqrt{\sum_{i=1}^n x_i^2}, (i = 1, 2, \dots, n) \quad (1)$$

- 3) 利用输入层的遥测样本数据、连接权  $\{W_{ij}\}$  和阈值  $\{\theta_j\}$ , 按照公式 (2) 计算中间层各单元的输入值、输出值;

利用中间层各单元的输出值、连接权  $\{V_{jt}\}$  和阈值  $\{\gamma_t\}$ , 按照公式 (3) 计算输出层各单元的输入、输出。

$$s_j = \sum_{i=1}^n w_{ij} \cdot a_i - \theta_j, b_j = f(s_j) \quad j = 1, 2, \dots, p \quad (2)$$

$$l_t = \sum_{j=1}^p V_{jt} \cdot b_j - \gamma_t, c_t = f(l_t) \quad t = 1, 2, \dots, q \quad (3)$$

4) 利用输出层各单元的输入和输出层的遥测样本数据, 按照公式 (4) 计算输出层各单元的一般化误差; 利用中间层各单元的输入值、输出层各单元的一般化误差和连接权  $\{V_{jt}\}$ , 按照公式 (5) 计算中间层各单元的一般化误差

$$d_t^k = (y_t^k - c_t) \cdot c_t(1 - c_t) \quad t = 1, 2, \dots, q \quad (4)$$

$$e_j^k = \left[ \sum_{t=1}^q d_t^k \cdot V_{jt} \right] \cdot b_j(1 - b_j) \quad j = 1, 2, \dots, p \quad (5)$$

5) 利用输出层各单元的一般化误差、中间层各单元的输入值和连接权  $\{V_{jt}\}$ , 按照公式 (6) 计算更新后的连接权和阈值; 利用中间层各单元的一般化误差、输入层的遥测样本数据和连接权  $\{W_{ij}\}$ , 按照公式 (7) 计算更新后的连接权和阈值。

$$V_{jt}(iter + 1) =$$

$$V_{jt}(iter) + \alpha \cdot d_t^k \cdot b_j, \gamma_t(iter + 1) = \gamma_t(iter) + \alpha \cdot d_t^k \quad (6)$$

其中:  $iter$  为学习过程的迭代次数;  $\alpha$  为学习率, 设置经验值 0.01。

$$W_{ij}(iter + 1) =$$

$$W_{ij}(iter) + \beta \cdot e_j^k \cdot a_i^k, \theta_j(iter + 1) = \theta_j(iter) + \beta \cdot e_j^k \quad (7)$$

其中:  $\beta$  为学习率, 设置经验值 0.01。

6) 随机选取下一组遥测数据样本组提供给模型, 返回步骤 2, 直至全部遥测数据样本学习完毕, 完成一次 BP 神经网络模型的学习。

7) 重复步骤 2) 至 6), 直至由输出层各单元的输入值和输出层的遥测样本数据计算所得的网络全局误差函数  $E \leq \epsilon$ ; 或者, 当学习次数大于预先设定值, 强制神经网络停止学习。其中,  $\epsilon$  为网络性能目标误差。

$$E = \frac{1}{2} \sum_{k=1}^m E_k, E_k = \frac{1}{2} \sum_{t=1}^q (y_t^k - c_t)^2 \quad (8)$$

通过自主学习获得的神经网络模型以关系数据库的形式存储于知识库, 便于在线故障诊断部分能够通过参数标识映射表快速地获得所需的网络模型。同时, 知识库的关系型数据结构便于日常的维护。同时, 在故障诊断的过程中利用不断产生的新样本数据信息, 进行神经网络的重新自主学习, 实时更新知识库的网络模型。通过不断的加入新信息, 使知识库能够及时反映系统当前遥测参数的特征。

### 2.3 实时在线故障诊断

通过离线自主学习获得相应的神经网络模型后, 实时在线故障诊断部分能够依据知识库中相应的神经网络模型, 对遥测数据进行实时在线的诊断。实时在线故障诊断的主要流程: 实时数据库将接收的遥测数据进行高速缓存并分发; 遥测数据预处理模块对遥测数据中的不连续、跳码等非平稳现象进行预处理并分类输送至对应的功能模块; 根据提取的遥测数据标识从知识库获取相应的神经网络模型; 利用模型计算相应遥测参数的神经网络预测值; 故障诊断模块利用神经网络模型预测值对遥测参数进行诊断, 并根据设定的阈值输出诊断结果。

在线故障诊断部分对遥测数据进行预处理后, 提取神经网络

的参数标识, 根据参数标识从知识库中查询并读入相应最新的神经网络模型; 同时对神经网络模型进行初始化参数设置。网络预测值计算模块通过特征遥测参数计算被诊断遥测参数的期望值, 作为故障诊断模块的诊断依据。故障诊断模块依据神经网络的输出信号, 采用阈值逻辑判决方法生成精确的故障诊断结果; 通过监控终端进行故障报警并将故障信息提交测试人员或者启动更新的神经网络自主学习。

具体过程如下: 如果  $\{|y - E(\{x_1, x_2, \dots, x_n\})| < \psi\}$ , 那么将遥测数据作为新样本存入数据库并启动神经网络的自主学习; 否则, 系统发出故障警报。其中,  $y$  为被诊断遥测参数,  $E(\{x_1, x_2, \dots, x_n\})$  为神经网络通过特征遥测参数计算的期望值。门限阈值  $\psi = 1.2 \times \max\{e(1), e(2), \dots, e(m)\}$ , 即 1.2 倍卫星正常工作状态下神经网络输出最大误差。

## 3 实验及结果分析

### 3.1 实验结果

为了验证基于 BP 神经网络的卫星故障诊断方法的有效性和优越性, 以现有型号三轴稳定近地卫星控制分系统为实验对象, 利用本文方法对具有代表性的红外地球敏感器和动量轮的相关遥测进行分析。训练过程中, 设置最大训练次数 500 000, 训练所要达到的目标精度  $1 \times 10^{-5}$ 。

本文所用人工神经网络的训练集和测试集样本均来源于控制分系统实际测试过程中产生的遥测数据。在创建神经网络模型之前, 先对数据进行预处理, 找出无效数据的位置, 以无效数据为中心点, 左右各取等长度区间的有效数据作为样本集, 若一端数据不足时, 向另外一端进行扩充。由于输入样本各参数的集中取值范围不同, 参数大小不一, 为了使各类参数所起的作用大致相同, 必须对输入数据进行归一化, 把输入数据都归一化到  $[-1, 1]$  区域内。在取得训练所需的样本数据后, 对 BP 神经网络进行了离线训练。针对红外地球敏感器和动量轮的神经网络模型, 分别进行了训练。其中, 红外地球敏感器的样本数量 437, 以红外弦宽、红外前基、地心距作为输入模式, 以红外滚动估值作为输出模式; 动量轮的样本数量 115, 以滚动角度估值、滚动角速度估值作为输入模式, 以动量轮转速脉冲作为输出模式。

为了验证所得到神经网络的有效性, 利用训练得到的神经网络模型对遥测数据进行诊断, 计算神经网络的预测值与实际遥测值的误差, 实验结果如图 3 (b)、图 4 (b) 所示。其中, 红外地球敏感器的诊断阈值为  $0.02^\circ$ , 动量轮脉冲的诊断阈值为 15 个/min。从误差变化图可以看出, 超出阈值范围的遥测数据均为异常数据, 进而能够准确地诊断出故障发出警报。

同时, 本文利用 Kalman 滤波算法对测试集中同样的数据进行故障诊断。为了方便与 BP 神经网络算法的结果进行对比, 同样给出了预测值精度和误差变化图, 使用同样的诊断阈值, 如图 3 (a)、图 4 (a) 所示。

### 3.2 结果分析

利用历史数据库中的样本集进行训练学习后, 对于给定的遥测参数, 即可利用完成训练的神经网络预测模型确定其期望值。通过神经网络预测值与实际遥测值 (理论值) 的对比与分析, 验证神经网络模型的准确性与可靠性。

通过分析以上实验中遥测数据的期望值与实际遥测值的对比结果可知, 在对同一组测试数据进行故障诊断时, 基于 Kalman

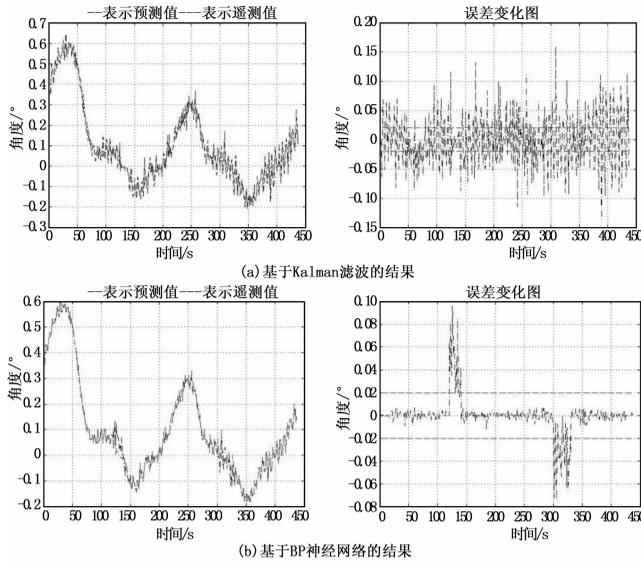


图 3 红外地球敏感器诊断结果

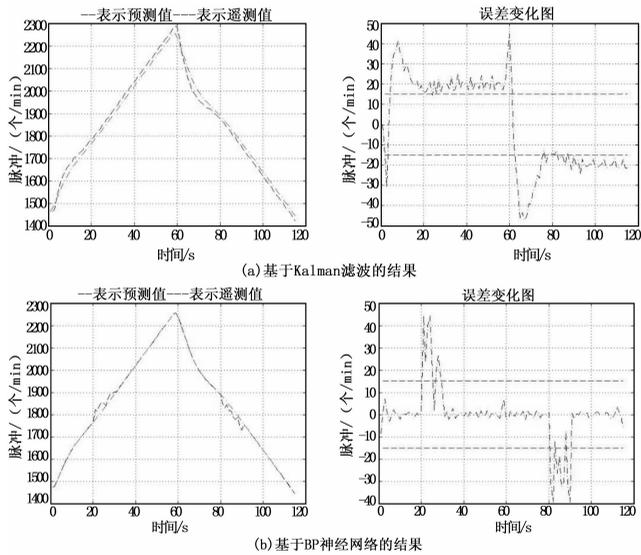


图 4 动量轮脉冲诊断结果

滤波的方法预测出遥测数据的期望值与真实遥测数据的误差较大, 红外滚动估值的预测误差在  $0.1^\circ$  左右, 动量轮脉冲的预测误差在 40 个/min 脉冲左右。由图可知, 利用设定的阈值  $0.02^\circ$  和 15 个/min 无法对测试样本集中遥测数据微小的误差

进行诊断。相对于基于 Kalman 滤波的方法, 基于 BP 神经网络的方法能够准确地预测出遥测数据的期望值, 红外滚动估值的预测误差在  $0.01^\circ$  以内, 动量轮脉冲的预测误差在 8 个/min 脉冲以内; 通过设定的诊断阈值  $0.02^\circ$  和 15 个/min, 能够准确地诊断出异常故障。

从而证明了本文建立的 BP 神经网络模型是可靠且有效的。利用故障诊断阈值, 本文方法能够有效地对卫星的故障进行诊断。经分析, 预测误差主要来自于神经网络训练样本不足造成的神经网络训练不充分, 利用实时在线故障诊断子系统中更新的神经网络自主学习能力可以减小预测误差。

### 4 结论

本文通过对卫星遥测数据的特性分析, 利用 BP 神经网络来挖掘其中隐藏的规律, 并构建了基于 BP 神经网络的卫星故障诊断系统。利用红外地球敏感器和动量轮的遥测数据对算法进行验证, 与基于 Kalman 滤波的方法相比, 本文方法能够有效地、准确地对卫星故障进行诊断。由于神经网络的自学习功能, 神经网络模型会随着遥测数据的增多而不断提高预测精度, 这会进一步提高卫星故障诊断的准确性。为了将本文方法应用于实际测试过程中, 后续需要解决从知识库的大量神经网络模式中快速查询相应模型的问题。

本文方法应用于卫星的故障诊断, 能够提高卫星测试的智能性、自主性与实时性。同时, 本文的方法对于卫星的在轨自主管理具有一定的参考价值。

### 参考文献:

- [1] 冯文婧, 潘宇倩, 白东炜. 应用层次分析法的航天器健康评估方法 [J]. 航天器工程, 2014, 23 (2): 12-18.
- [2] 朱维宝, 李砥擎, 孙波. 人工智能技术在航天器数据监视中的应用研究 [J]. 航天器工程, 2007, 16 (3): 94-98.
- [3] 岑朝辉, 魏蛟龙, 蒋睿. Elman 神经网络的红外地球敏感器实时故障诊断 [J]. 振动、测试与诊断, 2010, 30 (5): 504-509.
- [4] Satish Kumar. 神经网络 [M]. 北京: 清华大学出版社, 2006.
- [5] 张芝兰. BP 神经网络研究及其在个人信用评估中的应用 [D]. 长沙: 中南大学, 2012.
- [6] 张旭东, 李运泽. 基于 BP 神经网络的纳卫星轨道温度预测 [J]. 北京航空航天大学学报, 2008, 34 (12): 1423-1427.
- [7] 邓建国, 罗隆福. 基于 BP 神经网络的大型水轮发电机定子铁心的温度预测 [J]. 湖南大学学报, 2000, 27 (1): 72-75.
- [8] 郭阳明, 冉从宝, 姬昕禹, 等. 基于组合优化 BP 神经网络的模拟电路故障诊断 [J]. 西北工业大学学报, 2013, 31 (1): 44-48.
- [9] 吕明, 吴晓蓓, 陈庆伟, 等. 多包传输网络控制系统的鲁棒  $H_\infty$  故障检测 [J]. 控制与决策, 2008, 23 (2): 221-224.
- [10] 杨业, 王永骥. 一类多包传输网络控制系统的设计及稳定性分析 [J]. 2005, 34 (2): 129-132
- [11] Li YH, Zhang Y. Robust  $H_\infty$  Control for NCS with Time-varying Sampling Period and Random Packet Dropouts [J]. Computing Technology & Automation, 2013.
- [12] Zhang Q, Li Y, Zhang Y, et al.  $H_\infty$  controller design of networked control systems with time-varying sampling periods [A]. Proceedings of 2010 Chinese Control and Decision Conference [C]. 2010: 145-149.
- [13] Zhang HL, Jing YW, Zhang SY. Controller design for networked control systems with active varying sampling period [J]. Journal of System Simulation, 2009, 21 (22): 7275-7280.

(上接第 58 页)

- [6] Mao Z H, Jiang B. Sliding mode observer - based fault estimation for nonlinear networked control systems [A]. Proceedings of the 27th Chinese Control Conference [C]. Piscataway, NJ, USA: IEEE, 2008: 47-51.
- [7] Zhu Z, Jiao X. Fault detection for nonlinear networked control systems based on fuzzy observer [J]. Journal of Systems Engineering & Electronics, 2012, 1 (1): 129-136.
- [8] 樊金荣, 方华京. 具有时变采样周期的网络化控制系统故障检测 [J]. 计算机工程, 2013, 3 (3): 289-294.
- [9] 吕明, 吴晓蓓, 陈庆伟, 等. 多包传输网络控制系统的鲁棒  $H_\infty$  故障检测 [J]. 控制与决策, 2008, 23 (2): 221-224.