

智能装备故障预测与健康管理系统研究

黄忠山^{1,2}, 田凌^{1,2}

(1. 清华大学机械工程系, 北京 100084;
2. 精密超精密制造装备及控制北京市重点实验室, 北京 100084)

摘 要: 针对智能装备预测性维护存在的智能化和网络化程度不高、物理模型建模困难等问题, 研究了数据驱动的智能装备远程故障预测与健康管理系统(PHM)的实施框架、关键技术和系统开发方法。具体阐述了数据驱动 PHM 系统的运行模式, 在此基础上分析了 PHM 系统的软件架构和关键技术, 首先利用 EEMD 对原始信号进行降噪和重构, 将重构后的信号作为输入建立基于 RBF 神经网络的故障诊断模型; 然后采用动态神经网络建立基于时间序列的故障预测模型, 并建立基于故障阈值的故障报警机制; 最后利用混合编程和网络化开发技术开发了数据驱动的远程 PHM 系统。实际应用结果表明, 该系统能以较高效率完成故障诊断、故障预测等核心功能, 具有良好的实用性。

关 键 词: 智能装备; PHM; 数据驱动; 智能化; 网络化

中图分类号: TP 206

DOI: 10.11996/JGj.2095-302X.2018050855

文献标识码: A

文章编号: 2095-302X(2018)05-0855-07

Research on Prognostics and Health Management System

HUANG Zhongshan^{1,2}, TIAN Ling^{1,2}

(1. Department of Mechanical Engineering, Tsinghua University, Beijing 100084, China;

2. Beijing Key Lab of Precision/Ultra-Precision Manufacturing Equipment and Control, Beijing 100084, China)

Abstract: To solve the problems existing in the intelligent maintenance of intelligent equipment such as low-level intelligentization, networking and the difficulty of establishing physical model, the research is made on the framework, key technologies and system development methods of the data-driven remote prognostics and health management system (PHM) for intelligent equipment. The operating mode of the data-driven PHM system is specifically described. Based on it, the software architecture and key technologies of the PHM system are analyzed. First, the EEMD is used to denoise and reconstruct the original signal, and the reconstructed signal is applied as the input to establish the diagnostic model based on RBF neural network. Then the fault prediction model based on time series is established by dynamic neural network, and the fault alarm mechanism based on the fault threshold is set up. Finally, the hybrid programming and networking are employed to develop the data-driven remote PHM system. The practical application results show that the system, with a good practicability, can efficiently perform the core functions of fault diagnosis and prediction.

Keywords: intelligent equipment; PHM; data driven; intelligentization; networking

收稿日期: 2018-01-15; 定稿日期: 2018-03-30

第一作者: 黄忠山(1989-), 男, 广西南宁人, 硕士研究生。主要研究方向为深度学习、智能故障诊断。E-mail: huangzs15@mails.tsinghua.edu.cn

通信作者: 田凌(1963-), 女, 辽宁铁岭人, 教授, 博士。主要研究方向为机械制造及自动化、数字化制造。E-mail: tianling@tsinghua.edu.cn

智能装备是具有预测、感知、分析、推理、决策、控制功能的各类装备的统称,是在装备数控化基础上提出的一种更先进、更能提高生产效率和制造精度的装备类型,如高端数控机床、工业机器人等,其发展的关键技术包括故障诊断、健康维护技术等^[1]。故障预测与健康管理技术(prognostics and health management, PHM)^[2]是未来智能装备系统保障维护的发展方向。随着智能装备越发复杂化,建立复杂智能装备的部件或系统的数学或物理模型十分困难。因此,相比于物理解析模型,利用部件或系统全生命周期中各阶段的历史数据进行建模,将更加有利于 PHM 功能的实现^[3]。

一些学者对数据驱动的 PHM 进行了研究,文献[4]从数据驱动的角度出发对复杂装备的 PHM 应用进行了研究;文献[3-5]对数据驱动故障监测、诊断和预测方法进行了总结;文献[6]对开发基于数据驱动的机载设备 PHM 软件系统进行了研究;文献[7]对航空发动机状态监测关键技术进行了阐述;文献[8]利用机器学习对数字电路的故障预测与健康方案进行了研究;文献[9]研究了基于数据驱动的故障预测框架。考虑到智能装备正朝着信息化、智能化和网络化的方向发展,这就要求其维护方法也必须实现智能化和网络化,上述文献为实现智能装备 PHM 维护方法的智能化提供了重要借鉴。然而,基于机器学习和智能算法的 PHM 系统在方法和应用上仍需要进一步研究,且在网络化方面展开的研究工作相对较少。

因此,为了解决智能装备复杂化而导致的物理模型建模难问题,满足智能装备维护任务的智能化和网络化需求,本文从数据挖掘的角度出发,采用智能算法、利用 MATLAB 较强的数据处理能力和 Java web 在网络化方面的优势,采用混合编程的方式,开发基于数据驱动的远程 PHM 软件系统,以期智能装备的智能维护工作提供有力支持。

1 PHM 系统架构分析

1.1 数据驱动 PHM 系统运行模式

智能装备的数据驱动 PHM 系统按功能可分为 6 大部分:数据采集、信号处理、状态监测、故障诊断、故障预测、维护决策^[10-11],其运行模式如图 1 所示。首先各类传感器对智能装备的运

行信号进行采集,对信号进行预处理和特征提取后,利用监测模型进行状态监测和故障诊断,利用预测模型进行故障预测,为设备的维护决策提供支持。

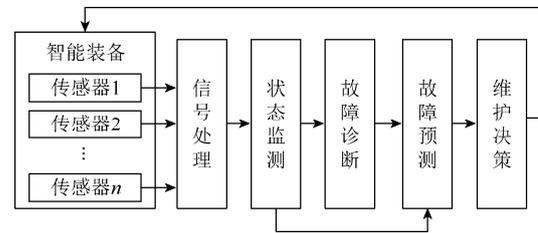


图 1 数据驱动 PHM 系统运行模式

(1) 信号处理。其包括两部分:①进行数据预处理,如对缺失数据进行插值处理、数据异常值剔除、提取相关信号等;②针对不同的信号类型的特点进行信号特征提取,比如统计特征分析、小波分解^[12]、经验模态分解等。

(2) 状态监测。对特征信息进行实时监测,得到智能装备运行状态,为故障报警、故障诊断、故障预测提供历史监测与统计数据。

(3) 故障诊断。对故障信号进行离线或在线诊断,本系统采用基于总体经验模态分解法(ensemble empirical mode decomposition, EEMD)和径向基神经网络(radial basis function, RBF)故障诊断方法进行故障诊断建模,确定故障类型。

(4) 故障预测。其为 PHM 的核心技术和能力,在状态监测与故障诊断信息的基础上,对关键参数进行时间序列上的故障预测,实现故障提前感知能力。智能装备的运行参数一般呈现非线性和非平稳性,针对该特点,本文采用动态神经网络进行模型建立和故障预测。

(5) 维护决策。维护人员根据状态监测、健康评估和故障预测结果进行,评估和判定智能装备的总体健康状态,采取合适的维护策略进行维护。

1.2 远程数据驱动的 PHM 系统软件架构

分析和明确 PHM 运行模式是构建 PHM 系统软件架构的基础。基于 PHM 系统的运行模式,远程数据驱动 PHM 系统首先从智能设备工作现场采集数据,通过 Internet 把数据传输到数据库服务器;状态监测、故障诊断、故障预测等各类智能故障分析模型在专业软件、硬件的支持下,对数据进行分析;用户则直接通过浏览器进行 Web 请求传送数据、获取故障分析结果与解决方案等。

将远程数据驱动的 PHM 系统软件架构总体设计为 3 层, 如图 2 所示。软件最下层是底层资源层及其 API 层, 中间层是业务逻辑层, 顶层是界面

应用层; 同时, 该系统可通过相应的 API 接口实现对外部故障信息的访问和查询, 拓宽了系统的开放性。

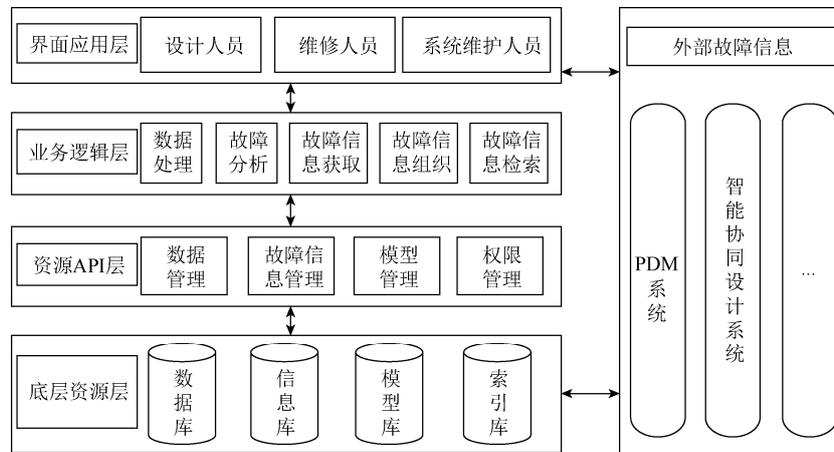


图 2 远程数据驱动 PHM 系统软件架构

(1) 底层资源层。存放各种故障诊断信息, 包括故障的数据库、故障信息库, 以及存放智能算法模型的模型库、外部故障信息的索引库等。

(2) 资源 API 层。提供对底层资源层的操作与管理接口, 包括对底层资源层的数据管理、知识管理、模型管理、权限管理等。

(3) 业务逻辑层。实现 PHM 系统的业务逻辑, 通过调用底层的平台资源实现业务逻辑, 包括数据处理、故障诊断与预测智能算法模型构建、故障知识获取、故障知识组织、故障知识检索等。

(4) 界面应用层。界面应用的 UI 层, 向装备设计人员、准备维修人员、系统维护人员提供故障预测与健康管理系统相关应用功能。

(5) 外部故障信息。分布在不同业务系统中的产品生命周期内的故障信息, 这些信息资源包括数据、文档、模型、算法等多种类型。

2 PHM 系统关键技术实现

2.1 基于 EEMD 和 RBF 的故障诊断方法

2.1.1 EEMD 信号分解方法

监测信号中存在的噪声对故障诊断的准确性带来干扰, 因此需要对监测信号进行降噪处理。常用的降噪方法有小波分解、EMD 分解、EEMD 分解等。其中, EEMD 通过加入噪声的方法解决了 EMD 降噪中模态混叠问题, 增强了降噪的效果, 也克服了小波基函数和阈值的选择^[13]。

EEMD 具体实现步骤如下^[14]:

步骤 1. 向采集信号 $x(t)$ 中加入白噪声得到 $x'(t)$ 。

步骤 2. 将加入白噪声的信号 $x'(t)$ 进行 EMD 分解得到各 IMF 分量。

步骤 3. 计算 N 次分解后每一个 IMF 的总体均值作为最终结果, IMF 总体均值为

$$IMF_i = \frac{1}{N} \sum_{n=1}^N a_{i,n}, \quad i=1,2,\dots,p \quad (1)$$

其中, $a_{i,n}$ 为第 n 次分解得到的第 i 个 IMF 分量。

2.1.2 RBF 神经网络结构

RBF 神经网络^[15]是一种具有单隐层的 3 层前向网络, 能以任意精度逼近任意连续函数, 克服了 BP 神经网络存在的局部最小值和收敛速度慢的缺陷, 且结构简单、需设置参数少, 因此被广泛应用。

常用高斯核函数作为隐含层基函数的形式

$$\varphi_j(\mathbf{X}) = \exp\left(-\frac{\|\mathbf{X} - \mathbf{c}_j\|^2}{2\sigma_j^2}\right), \quad j=1,2,\dots,p \quad (2)$$

其中, $\mathbf{X} = [x_1, x_2, \dots, x_n]$ 为 n 维输入向量; \mathbf{c}_j 为第 j 个基函数的中心; σ_j 为第 j 个神经元的标准化常数, 即高斯基函数的方差; n 、 p 分别为输入层和隐含层的神经元的个数。

确定了隐含层函数后, RBF 网络输入和输出之间的关系表达式为

$$y_i = \sum_{j=1}^p w_{j,i} \varphi_j(X), \quad i=1,2,\dots,m \quad (3)$$

其中, m 为输出层神经元的个数; y_i 为输出层第 i 个神经元的输出值; $w_{j,i}$ 为隐含层第 j 个单元与输出层第 i 个单元之间的连接权值。

2.1.3 基于 EEMD 与 RBF 网络的故障诊断建模

本文利用 EEMD 和 RBF 网络进行故障诊断建模, 利用 EEMD 方法对监测信号进行特征提取, 将特征向量作为 RBF 神经网络的输入, 建立基于 EEMD 和 RBF 神经网络故障诊断模型。

首先对原信号进行降噪重构, 步骤如下:

步骤 1. 利用 EEMD 方法对原监测信号进行分解得到 p 个 IMF 分量, 根据相关系数计算式(4)求出 p 个 IMF 分量与原信号的相关系数 $r_j (j=1,2,\dots,p)$, 即

$$r_j = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (4)$$

其中, r_j 为第 j 个 IMF 分量与原信号的相关系数。

步骤 2. 对 p 个相关系数 r_j 从大到小排列, 即 $r_1 > r_2 > \dots > r_p$, 并记对应的 IMF 分量的排列为 $IMF_1, IMF_2, \dots, IMF_m$ 。根据累积相关度 r_{sum} 大于总相关阈值 λ_{rg} 确定前 m 个相应的 IMF 分量, 即,

$$r_{\text{sum}}(m) = \sum_{k=1}^m r_k > \lambda_{rg}。 \text{ 本文取 } \lambda_{rg} = 0.98。$$

步骤 3. 利用选取的 m 个 IMF 分量重构信号, 得到重构信号: $x(t)_{rs} = IMF_1 + IMF_2 + \dots + IMF_m$ 。

然后, 对重构信号 $x(t)_{rs}$ 进行特征提取。考虑到故障信号既可能反映了物理冲击特征, 也可能体现出不同的能量变化以及离散程度, 本文通过统计信号的峭度 K 以反映故障信号受冲击特征, 通过统计信号的能量值 E 反映不同信号的能量特征, 通过统计信号的标准差 σ 反映信号的离散程度。记信号的均值为 μ , 则各特征统计量的计算式为

$$\begin{cases} K = \frac{E(x_i - \mu)^4}{\sigma^4} \\ E = \int_{-\infty}^{+\infty} |c_i(t)|^2 dt \\ \sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \end{cases} \quad (5)$$

设有 n 组故障信号样本, 则每组故障信号经 EEMD 信号重构与特征提取后可提取出 3 维度的特征, 则 n 组故障信号样本构成 $n \times 3$ 信号特征矩阵

$$D = \begin{bmatrix} K_1 & E_1 & \sigma_1 \\ K_2 & E_2 & \sigma_2 \\ \vdots & \vdots & \vdots \\ K_n & E_n & \sigma_n \end{bmatrix}_{n \times 3} \quad (6)$$

最后, 将信号特征矩阵 D 作为 RBF 网络的输入, 建立基于 RBF 网络的故障诊断模型, 步骤如下:

步骤 1. 确定输入向量。以归一化特征向量 D 作为输入向量, 消除量纲带来的影响。

步骤 2. 确定输出向量。对 n 个故障类型进行二进制编码, 以该二进制向量作为输出向量。

步骤 3. 参数初始化, 包括中心参数和宽度初始化。

步骤 4. 给定学习因子进行网络迭代训练, 获取故障诊断模型, 迭代算法为

$$\begin{cases} E = \frac{1}{2} \sum_{p=1}^N \sum_{k=1}^L (t_k^p - y_k^p)^2 \\ \Delta c = -\eta \frac{\partial E}{\partial c} \\ \Delta w = -\eta \frac{\partial E}{\partial w} \\ E \leq \varepsilon \end{cases} \quad (7)$$

其中, E 为评价函数; N 为输入样本组数; L 为网络输出单元数; t 为目标输出值; η 为学习因子; ε 为迭代终止条件。

系统将根据上述建立的诊断模型对故障信号进行故障诊断, 通过输出二进制向量确定相应的故障类型诊断, 从而完成故障诊断流程。

2.2 基于动态神经网络的故障预测建模

一些监测信号时间序列本身具有较强的自相关性, 可以利用信号的这种自相关性预测该时间序列的未来时刻值。常用的时间序列建模方法有自回归滑动平均(auto-regressive moving average, ARMA)模型、人工神经网络(artificial neural network, RNN)等方法。本文引入非线性自回归(nonlinear auto-regression, NAR)动态神经网络^[16]对监测信号时间序列进行建模。一般静态神经网络是将输入信号从输入层开始再从前往后依次经过各层处理, 最终通过输出层神经元输出结果; 而 NAR 等动态网络能够将输出信号反馈到输入端

从而将输出信号参与到下一次迭代训练中, 具有记忆功能, 因此可以更好地描述具有非平稳、非线性等复杂映射关系的时变系统的特性^[17], 克服了 ARMA 模型只能针对平稳线性信号进行建模的缺陷。

NAR 神经网络可以定义为

$$\hat{y}(t+1) = f[y(t), y(t-1), \dots, y(t-n_y)] \quad (8)$$

其中, f 为非线性映射; $y(t), y(t-1), \dots, y(t-n_y)$ 为监测信号的历史时间序列; $\hat{y}(t+1)$ 为预测值。

根据式(8)可以预测时间序列的变化趋势, 若预测的变化趋势大于某一临界值, 则系统提前警报, 从而建立智能装备的故障预测模型

$$\hat{y}(t+k) > y_g \quad (9)$$

其中, $\hat{y}(t+k)$ 为时间序列的第 k 步的预测值; y_g 为故障报警的阈值。

2.3 基于混合编程的系统网络化开发

2.3.1 系统网络化开发技术

本系统采用 B/S 开发模式, 在该模式下客户只需要通过浏览器即可访问服务器获取 PHM 功能服务, 实现远程 PHM 能力。在 Java web 开发方面, 以 J2EE 为框架, 采用基于 SSM 框架的系统 MVC 开发模式, 总体开发环境见表 1。

表 1 PHM 软件系统开发环境

项目	内容
操作系统	Windows10
开发工具	Eclipse、MATLAB R2017a
开发语言	Java、JavaScript、HTML、CSS、SQL
Web 服务器	Tomcat7
开源包	Spring4、SpringMVC4、Mybatis3
数据库	MySQL

2.3.2 Java 和 MATLAB 混合编程技术

MATLAB 和 Java 混合编程的步骤如下:

步骤 1. 在 MATLAB 中编写 m 文件。

步骤 2. 在 MATLAB 的命令行里输入 deploytool, 在弹出的菜单中选择 Library Compiler, 对 m 进行打包, 生成 jar 包。

步骤 3. 将 jar 包添加到 Java web 项目中, 通过对象调用 m 文件实现 MATLAB 的计算功能。

3 PHM 系统实现与应用验证

基于上述研究内容对某智能系统的齿轮箱

PHM 系统进行设计开发和初步应用验证。分别对齿轮箱滚动轴承故障进行故障诊断、对齿轮箱油温超限故障进行故障预测, 以验证网络化的 PHM 系统故障诊断、故障预测等关键功能的有效性。

对滚动轴承故障振动信号进行诊断, 共有 3 类故障信号: 滚动体故障、内圈故障、外圈故障, 每类故障信号共有 100 个样本。对其 3 类信号进行 EEMD 分解, 图 3 为滚动体信号 EEMD 分解结果。

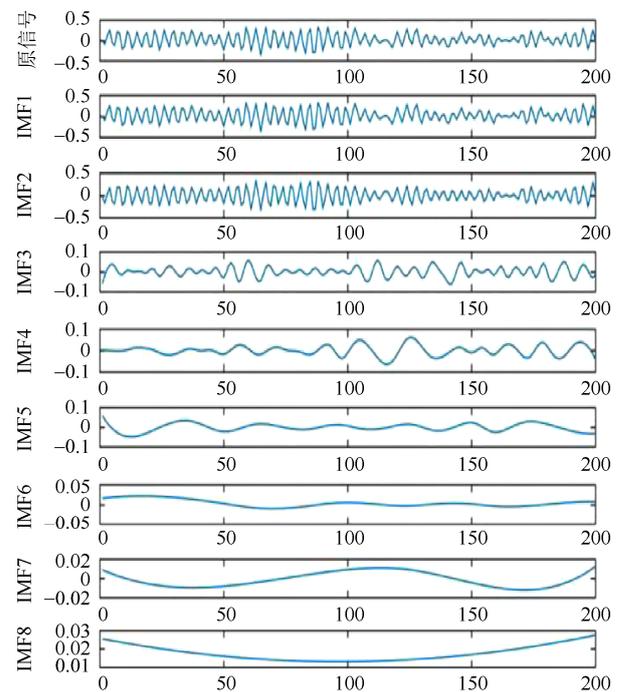


图 3 滚动体故障信号 EEMD 分解

基于 EEMD 分解结果, 根据原信号降噪重构步骤求得降噪后的重构信号, 并按照信号特征提取步骤信号特征, 得到 3 类故障信号的特征矩阵。滚动体故障信号特征矩阵为

$$D = \begin{bmatrix} 2.2700 & 4.7111 & 4.7111 \\ 2.5141 & 2.1285 & 0.1034 \\ \vdots & \vdots & \vdots \\ 3.1510 & 3.7061 & 0.1365 \end{bmatrix}_{100 \times 3}$$

对故障特征信号进行故障诊断建模。分别将故障样本总数的 70% 和 30% 作为训练集和测试集, 利用训练集训练诊断模型, 利用测试集测试模型的有效性。为了充分说明 RBF 网络的性能, 引入 BP 网络的测试结果进行对比分析, 设定的目标精度为 $goal=1 \times 10^{-10}$, 结果见表 2。

表2 两种故障诊断模型的诊断性能

方法	收敛步数	收敛时间(s)	故障识别率(%)
RBF网络	196	1.148	100
BP网络	349	1.931	100

从表2可看出,两种诊断模型对基于EEMD提取的故障特征信号的故障诊断识别率都达到100%,说明经EEMD分解重构的故障特征提取方

法的有效性,且RBF网络的收敛速度明显比BP网络快,说明了RBF诊断模型性能更为优良。

将远程数据驱动PHM系统实际应用于滚动轴承故障诊断中。用户通过浏览器登录本系统,依次将10组故障信号提交至系统进行诊断,诊断后的结果显示于界面中,如图4所示。经统计发现,系统对10组故障的诊断结果准确率为100%。实际应用证明了此系统对滚动轴承故障诊断的有效性。

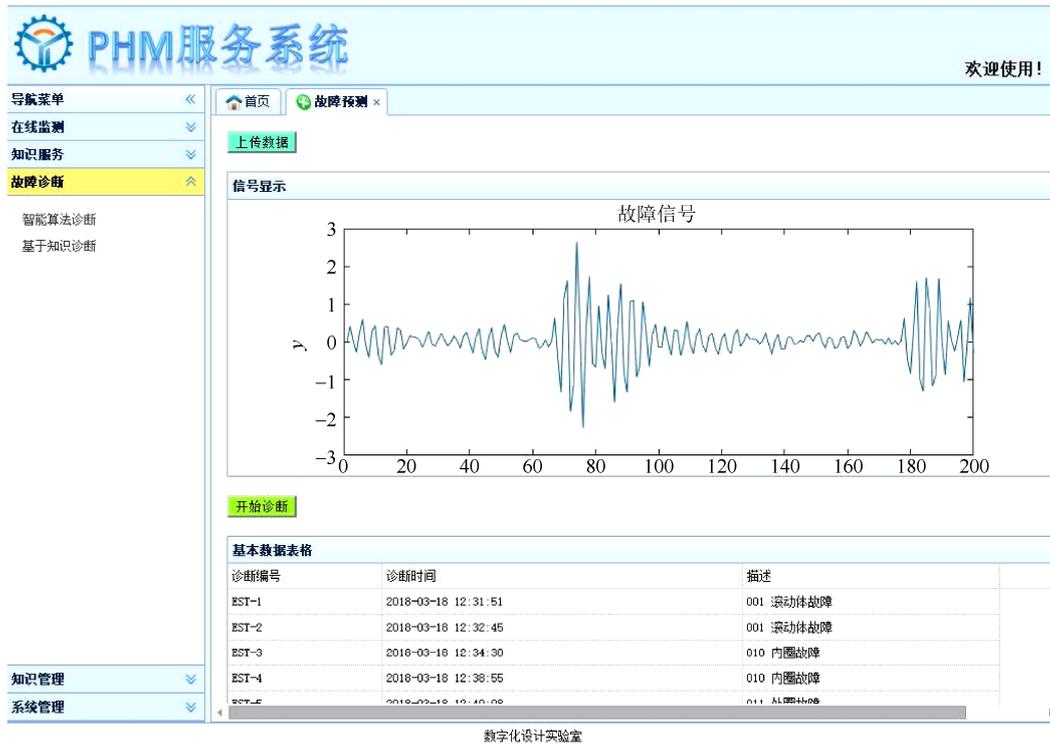


图4 远程数据驱动PHM系统故障诊断结果

若齿轮箱运行中油温温度过高,容易导致齿面发生胶合,造成齿面失效,因此有必要在齿轮箱运行过程中进行油温预测,以在油温超限前预警,便于提前采取措施降温。本文利用NAR动态网络对齿轮箱油温时间序列进行单步预测和故障预警。时间序列样本的采集时间间隔10min,总样本数为2880个。其中,训练样本为前2304个样本,测试样本为后576个样本。将常用的ARIMA(p, d, q)模型单步预测结果加入对比,按照该模型的参数确定方法^[18]确定为ARIMA(12, 1, 12)模型。两种模型的预测结果的均方误差(mean squared error, MSE)、平均绝对误差(mean absolute error, MAE)和警报正确率见表3。

从表3可看出,在对油温信号的趋势预测中,NAR模型的MSE和MAE均比ARIMA模型小,说明NAR模型的趋势预测更为准确;在此基础上,

NAR模型的警报正确率高于ARIMA模型,所以NAR模型能够更加有效地进行故障预测。

将远程数据驱动PHM系统实际应用于齿轮箱油温趋势预测中。系统对设备端进行远程状态监测和故障预测,预测值和真实值拟合较好,如图5所示。经统计发现,系统对油温超限的单步预测警报正确率超过90%。实际应用表明该系统具有较高的油温超限预测准确度,实现了故障预测能力。

上述应用结果表明,本文所开发的远程数据驱动PHM系统能以较高效率实现故障诊断、故障预测等核心功能,具有良好的实用性。

表3 两种故障预测模型的预测统计结果

模型名称	MSE	MAE	警报正确率(%)
NAR网络	0.9649	0.5928	91
ARIMA	14.2272	3.3839	83

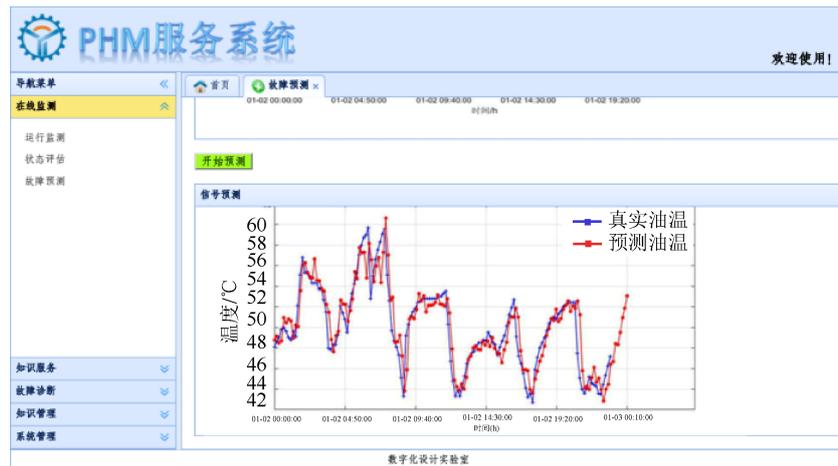


图5 远程状态监测与故障预测

4 结束语

智能装备对智能化、网络化的维护需求正逐步提高,PHM技术是未来智能装备智能维护的发展方向。本文针对智能装备预测性维护存在的智能化和网络化程度不高、物理模型建模困难等问题,从数据挖掘的角度出发,结合智能算法和混合编程网络开发技术,研究和开发了基于数据驱动的远程PHM系统。应用结果表明,该系统能以较高效率完成故障诊断、故障预测等核心功能,其开发模式和核心技术为PHM系统的开发提供了借鉴意义。

参考文献

- [1] 傅建中. 智能制造装备的发展现状与趋势[J]. 机电工程, 2014, 31(8): 959-962.
- [2] HESS A, FILA L. The Joint Strike Fighter (JSF) PHM concept: Potential impact on aging aircraft problems [C]// Proceedings of 2002 IEEE Aerospace Conference. New York: IEEE Press, 2002: 3021-3026.
- [3] 彭宇, 刘大同, 彭喜元. 故障预测与健康管理系统综述[J]. 电子测量与仪器学报, 2010, 24(1): 1-9.
- [4] 李向前. 复杂装备故障预测与健康管理系统研究[D]. 北京: 北京理工大学, 2014.
- [5] KABIR A, BAILEY C, LU H, et al. A review of data-driven prognostics in power electronics [C]// International Spring Seminar on Electronics Technology. New York: IEEE Press, 2012: 189-192.
- [6] 陈静, 彭宇, 李祺, 等. 数据驱动的机载设备PHM软件系统[J]. 电子测量与仪器学报, 2015, 29(10): 1536-1543.
- [7] 周媛. 基于数据驱动的航空发动机状态监测关键技术研究[D]. 南京: 南京航空航天大学, 2015.
- [8] 李永亮. 基于机器学习的故障预测与健康管理系统研究[D]. 成都: 电子科技大学, 2017.
- [9] 韩东, 杨震, 许葆华. 基于数据驱动的故障预测模型框架研究[J]. 计算机工程与设计, 2013, 34(3): 1054-1058.
- [10] JOHNS T, STREET N C, SHEPPARD J W, et al. IEEE standards for prognostics and health management [J]. IEEE Aerospace & Electronic Systems Magazine, 2007, 24(9): 34-41.
- [11] 李耀华, 尚金秋. 基于云计算的飞机PHM体系架构研究[J]. 计算机工程, 2017, 43(12): 6-10.
- [12] 高英杰, 孔祥东, ZHANG Q. 基于小波包分析的液压泵状态监测方法[J]. 机械工程学报, 2009, 45(8): 80-88.
- [13] WANG H, CHEN J, DONG G. Feature extraction of rolling bearing's early weak fault based on EEMD and tunable Q-factor wavelet transform [J]. Mechanical Systems & Signal Processing, 2014, 48(1-2): 103-119.
- [14] 马增强, 张俊甲, 王梦奇, 等. 基于改进EEMD和谱峭度的滚动轴承故障诊断[J]. 图学学报, 2017, 38(5): 663-669.
- [15] 柴保明, 张江涛, 史朋波, 等. 基于EEMD与RBF神经网络的齿轮故障诊断[J]. 煤炭工程, 2017(11): 145-147, 151.
- [16] 黄建风, 陆文聪. 基于小波-NAR神经网络的气象要素时间序列预测与天气指数彩虹期权估值[J]. 系统工程理论与实践, 2016, 36(5): 1146-1155.
- [17] MORDJAOUI M, HADDAD S, MEDOUED A, et al. Electric load forecasting by using dynamic neural network [J]. International Journal of Hydrogen Energy, 2017, 42(28): 17655-17663.
- [18] 杨军, 梅雪松, 冯斌, 等. 时序分析在电主轴热误差建模中的应用[J]. 计算机集成制造系统, 2015, 21(5): 1359-1367.