

# 基于灰色模型 KFMC 的航天发动机故障诊断算法

庄 夏

(中国民用航空飞行学院,四川 广汉 618307)

**摘 要:**针对以往的故障诊断方法往往基于已经采集的数据,无法对故障诊断进行及时预测,同时基于单一传感器的测量信息难以全面准确反映航天发动机工作状态,从而造成故障诊断的不确定和不精确的问题,提出了一种基于灰色模型 KFMC 数据融合的航天发动机故障诊断算法。采用有标签的训练数据初始化 KFMC 模型,将预测的数据采用 KFMC 模型估计其所属的故障类别以及隶属度,然后将数据对应各诊断类别的隶属度初始化传感器的初始信度分配,将各传感器采集的数据作为证据体,采用 DS 数据融合方法融合各证据体,获得最终的诊断结果。通过飞机发动机故障诊断实例进行实验,结果表明文中方法能正确及时地预测故障,克服了单个传感器故障诊断具有的不确定和不精确性,是一种适于航天发动机的故障诊断方法。

**关键词:**飞机发动机;故障诊断;模糊 K 均值;DS 数据融合;灰色模型

**中图分类号:**TP319

**文献标识码:**A

**文章编号:**1673-629X(2017)02-0130-04

**doi:**10.3969/j.issn.1673-629X.2017.02.029

## A Fault Diagnosis Algorithm of Aero Engine Based on Gray Model KFMC

ZHUANG Xia

(Civil Aviation Flight University of China, Guanghan 618307, China)

**Abstract:** The previous fault diagnosis model is based on the collected data, not able to predict the fault in time, and the traditional single measuring information based on the single sensor is not reflecting the working state of aero engine, therefore, leading to the uncertain and inaccurate problem. Aiming at the problems, an aero engine fault diagnosis method is proposed based on gray model KFMC and DS data fusion. The samples with labels is used to initialize the KFMC model and the predicted data uses the KFMC model to estimate the classification and its attributing probability for all the sensor data. Then the attributing probability is used to initialize the initial believe assign, the data collected by sensors is used as the evidence and the DS fusion method is used to fusion all the evidence to get the result. Simulation experiment is implemented to predict the fault, which also shows it solves the problems such as diagnosis uncertainty and inaccuracy and it is a diagnosis method suiting for aero engine.

**Key words:** aero-engine; fault diagnosis; fuzzy K-means; DS evidence fusion; gray model

### 0 引言

航天飞机发动机结构复杂,面临的环境复杂多变,因此,如何保证飞机发动机的安全可靠,是近年来航天飞机研究的重点课题<sup>[1-2]</sup>。由于航天飞机发动机上安装的传感器位置和数量的限制,以及传感器自身原因带来的测量误差,使得检测信息具有不确定性和不完备性<sup>[3]</sup>。因此,对飞机进行实时有效的故障诊断对于保证航天飞机的安全运行具有重要意义<sup>[4-5]</sup>。

文献[6]在对测试节点进行描述的基础上,考虑可靠性和测试代价等因素生成诊断二叉树,实现对可

疑集进行进一步隔离。文献[7]从 Mel 倒谱系数分析提取发动机振动的故障分类特征,分别采用 BP 网络和 RBF 网络对航天发动机进行故障识别。文献[8]对某航空飞机在空中停车时飞机的振动信号,采用二代小波进行分解,通过阈值处理并重构原始信号,并采用 FAST ICA 分离转子振动信号,最终提取故障诊断。文献[9]定义模糊加权有色网络给出两种产生式规则,设计采用 BP 神经网络多模糊加权有色网各参数进行学习的算法,最后应用参数学习后的有色网推理模型进行故障诊断。

收稿日期:2016-03-22

修回日期:2016-06-23

网络出版时间:2017-01-04

基金项目:四川省科技计划项目(2015GZ0279)

作者简介:庄 夏(1980-),男,硕士,副教授,研究方向为计算机网络。

网络出版地址: <http://www.cnki.net/kcms/detail/61.1450.TP.20170104.1102.098.html>

上述文献均对航天飞机发动机进行故障诊断具有重要意义,但其故障诊断的精度受限于样本的延时性。因此,文中设计了一种基于GM(1,1)预测和DS数据融合的故障诊断方法。该方法通过GM(1,1)预测传感器下一时刻的数据,利用DS数据融合理论进行融合,根据多个传感器的预测数据得到故障诊断结果。实验结果表明,该方法能较为精确地实现飞机发动机的故障诊断,克服了传统方法延时性的不足。

## 1 基于GM(1,1)模型的传感器数据预测

由于以往的航天飞机发动机故障诊断方法<sup>[10-14]</sup>往往基于目前已采集的传感器数据进行预测,具有一定延时性,而航天飞机具有很强的实时性需求,当实时采集了故障诊断征兆数据后,发动机已发生故障,这会极大地威胁航天飞机的安全性。

因此,下面采用基于GM(1,1)根据系统接收的所有传感器的历史数据,预测其在下一时刻可能的数据,再根据数据融合方法进行发动机故障诊断。

### 1.1 GM(1,1)概述

灰色模型GM(1,1)是一种对具有不确定因素的系统进行预测的有效方法。其能通过关联分析对原始数据进行生成处理,从而寻求系统变动的规律,生成具有较强规律性的数据序列,对事件的未来状态进行预测,是一种非常适合短时预测的模型。

$$x^0(k) + az^{(0)}(k) = b \quad (1)$$

其中,  $z^{(0)}(k)$  表示  $t=0$  时节点预测的  $t=1$  时的预测值;  $x^0(k)$  表示  $t=0$  时的节点采集数据。

### 1.2 基于GM(1,1)的下一时刻数据预测

采用灰色模型预测下一时刻在发动机表面传感器采集的数据进行预测,只需保存每个传感器前  $k$  个时刻的信息,就可以通过灰色模型预测传感器在  $k+1$  时刻的值。

采用灰色模型GM(1,1)对发动机表面传感器下一时刻采集的数据进行预测的过程可以描述为:

(1) 设在时刻  $k$  原始数据为  $n$  维向量,则可以表示为:

$$X^{(0)} = \{X^{(0)}(1), X^{(0)}(2), \dots, X^{(0)}(n)\} \quad (2)$$

(2) 对原始数据  $X^{(0)}$  进行一次累加操作,如式(3)所示:

$$X^{(1)} = \{X^{(1)}(1), X^{(1)}(2), \dots, X^{(1)}(n)\} \quad (3)$$

式(3)中,第  $k$  维向量  $X^{(1)}(k)$  可以根据式(4)进行计算:

$$X^{(1)}(k) = \sum_{i=1}^k X^{(0)}(i), k = 1, 2, \dots, n \quad (4)$$

(3) 对  $X^{(0)}$  进行光滑检验,如式(5)所示:

$$\rho(k) = \frac{X^{(0)}(k)}{X^{(1)}(k-1)} \quad (5)$$

(4) 判断  $X^{(1)}(k)$  是否满足指数规律,如式(6)所示:

$$\sigma^{(1)}(k) = \frac{X^{(1)}(k)}{X^{(1)}(k-1)} \quad (6)$$

(5) 生成  $X^{(1)}(k)$  的近邻域  $Z^{(1)}(k)$ , 如式(7)所示:

$$Z^{(1)}(k) = 0.5X^{(1)}(k) + 0.5X^{(1)}(k-1) \quad (7)$$

(6) 建立灰色微分方程,作为预测模型,如式(8)所示:

$$\frac{dX^{(1)}}{dt} + aX^{(1)} = u \quad (8)$$

求解式(8),得到  $X^{(1)}$  在下一时刻  $k+1$  的预测值,如式(9)所示:

$$\overline{X^{(1)}}(k+1) = (X^{(1)} - \frac{u}{a})e^{-ak} + \frac{u}{a} \quad (9)$$

(7) 估计式(9)中的参数  $u$  和  $a$ , 采用最小二乘估计,得到的结果如式(10)所示:

$$\begin{bmatrix} \frac{u}{a} \end{bmatrix} = (B^T B)^{-1} B^T X_N \quad (10)$$

其中,  $B$  和  $X_N$  分别表示为:

$$B = \begin{bmatrix} -Z^{(1)}(2) & 1 \\ -Z^{(1)}(3) & 1 \\ \vdots & \vdots \\ -Z^{(1)}(n) & 1 \end{bmatrix} \quad (11)$$

$$X_N = \begin{bmatrix} X^{(0)}(2) \\ \vdots \\ X^{(0)}(n) \end{bmatrix} \quad (12)$$

(8) 根据式(9)和式(10),采取累减法获得  $X^{(0)}$  在下一时刻  $k+1$  的预测值,如式(13)所示:

$$\overline{X^{(0)}}(k+1) = \overline{X^{(1)}}(k+1) - \overline{X^{(1)}}(k) \quad (13)$$

## 2 基于KFMC的加权故障诊断

$K$  均值聚类算法是一种无监督的算法,可以根据样本之间的某种评价准则,如最短欧氏距离实现无监督的分类。模糊  $K$  均值聚类算法是在  $K$  均值算法的基础上,引入隶属度权值,即对每个样本都赋予一个其可能所属分类的权值,表示该样本属于该类的隶属程度。

采用基于  $K$  均值的故障诊断聚类的具体过程可以描述为:

(1) 根据航天飞机发动机故障种类数初始化聚类个数  $K$ , 初始化聚类集合  $S_1, S_2, \dots, S_K$  为已有标签的传感器数据集,每个不同故障的聚类集合即为该类样本集合,随机选择该聚类数据的任意成员作为该类

的初始数据中心  $c_1, c_2, \dots, c_K$ 。

(2) 对于所有样本, 计算其与  $K$  个聚类中心的距离, 如式(14)所示:

$$J(W, C) = w_{ij}^m \sum_{k=1}^D \sum_{j=1}^K \|x_{ik} - c_{jk}\| \quad (14)$$

其中,  $w_{ij}$  表示每个数据样本  $x_i$  到各个数据聚类  $S_j$  的隶属度,  $w_{ij}$  满足  $\sum_{j=1}^K w_{ij} = 1 (1 \leq i \leq n)$ , 可以通过式(15)计算:

$$w_{ij} = \begin{cases} \left( \sum_{q=1}^K \left( \frac{\|x_i - c_j\|}{\|x_i - c_q\|} \right)^{2/(m-1)} \right)^{-1} \\ 1, \|x_i - c_q\| = 0 (i = q) \\ 0, \|x_i - c_q\| = 0 (i \neq q) \end{cases} \quad (15)$$

其中,  $1 \leq i \leq n, 1 \leq j \leq K$ 。

(3) 根据式(17)更新数据中心:

$$c_j = \frac{\sum_{i=1}^n w_{ij}^m x_i}{\sum_{i=1}^n w_{ij}^m}, 1 \leq j \leq K \quad (16)$$

(4) 获得样本所属的聚类: 根据式(17)将具有最小  $J(W, C)$  值的类作为样本所属聚类。

$$j = \operatorname{argmin}_j J(W, C) \quad (17)$$

(5) 当相邻 3 次迭代中所有聚类不再发生变化就得到最终的聚类中心, 否则转入步骤(2)继续迭代。

### 3 基于 DS 的诊断结果数据融合

当航天发动机上各类传感器采集的数据经过 ICA 提取独立成分后, 采用 FKC 对传感器感知的数据进行聚类, 得到每个数据所属的聚类的隶属度, 将其作为所属故障类别的基本信度分配, 再采用 DS (Dempster-Shafer) 理论进行数据融合, 得到最终的融合结果。

(1) 初始化命题, 命题种类的个数为故障类别数, 并将命题的集合作为辨识框架  $\Theta = \{F_1, F_2, \dots, F_n\}$ 。

(2) 对各传感器数据所得到的故障诊断类别的诊断结果进行归一化处理:

$$\begin{cases} M(k) = V_k \cdot y_i / \sum_{i=1}^k y_i \\ M(\Phi) = 1 - V_k \end{cases} \quad (18)$$

(3) 可信度分配: 根据式(18)获得归一化的诊断结果后, 对命题  $F_j$  第  $i$  个故障类别的基本可信度分配  $M_i(F_j)$  计算如下:

$$M_i(F_j) = \frac{y_i(F_j)}{\sum_{i=1}^c y_i(F_j)} \quad (19)$$

其中,  $y_i(F_j)$  为 KFMC 中第  $i$  个传感器数据在故障  $F_j$  的输出值。

(4) 证据合成: 根据 DS 证据合成规则对证据进行合并, 如式(20)所示:

$$\begin{cases} M(\Phi) = 0 \\ M(A) = K^{-1} \times \sum_{\cap A_i, 1 \leq i \leq n} \prod M_i(A_i) \end{cases} \quad (20)$$

其中,  $K = \sum_{\cap A_i, \emptyset} \prod_{1 \leq i \leq n} M_i(A_i)$ 。

(5) 计算命题  $F_j$  信任度:

$$\operatorname{Bel}(F_j) = \sum_{B \subseteq F_j} M(B) \quad (21)$$

其中,  $\operatorname{Bel}(F_j)$  表示对命题  $F_j$  为真的信任程度。

(6) 最终诊断: 根据各命题  $F_i (1 \leq i \leq n)$ , 可以得到当前预测的下一时刻  $k+1$  的数据, 对应的故障诊断融合结果即为  $F_{k+1}$ , 如下所示:

$$\begin{aligned} \operatorname{Bel}(F_{k+1}) &= \max \{ \operatorname{Bel}(F_j), F_j \in \Phi \} \wedge \\ &\quad \operatorname{Bel}(F_{k+1}) > \varepsilon_1 \wedge \varepsilon_1 \in R \wedge \varepsilon_1 > 0 \end{aligned} \quad (22)$$

其中,  $\max$  表示取最大值, 即诊断融合结果  $F_{k+1}$  对应了 KFMC 中诊断结果  $F_i (1 \leq i \leq n)$  中具有最大可信度的故障种类, 且概率分配值满足某预设阈值  $\varepsilon_1$ 。

### 4 仿真实验

为了对文中方法进行验证, 以航天飞机 MA600 为例, 对其发动机上最易发生故障的部位油箱进行故障诊断, 用变量  $y_0, y_1, y_2, y_3$  和  $y_4$  表示无故障、输油泵故障、活门故障、输油管路泄漏、油箱泄漏等故障类别, 用变量  $x_0, x_1, x_2, x_3$  和  $x_4$  表示油箱油位过低、输油泵电流过大、输油泵出口压力过大、单向活门出口压力过大和输油管道的压力过大等故障征兆属性。

在采集了 100 组训练样本数据后, 根据该样本的标签, 将其初始化 KFMC 中的各聚类, 并随机选择该聚类的成员作为它的初始数据中心。然后, 在线采集传感器的数据, 传感器的个数为 4 个, 对应了 4 个证据体, 在每个时刻采集数据后, 就将其添加到该传感器的历史采集数据后, 采用其通过灰色模型来预测下一时刻的数据。

将各传感器在下一时刻的预测值输入到 KFMC 中, 得到所属故障类别, 将得到的权值作为数据所属该类的基本信度分配。

从表 1~4 可以看出, 仅从单个传感器的数据对发动机油箱的故障进行诊断, 会出现不确定情况, 不能明确得到数据所属的故障诊断类别。

而从表 4 中可以发现, 文中基于灰色模型和 DS 数据融合的故障诊断方法, 能实现多个传感器的故障诊断结果的融合, 消除单个传感器故障诊断出现的不确定现象。

表 1 证据体  $E_1$  单独作用下的基本可信度和诊断结果

诊断数据	故障类别	$M(u_0)$	$M(u_1)$	$M(u_2)$	$M(u_3)$	$M(\Phi)$	诊断结论
1	$\gamma_0$	0.707 8	0.139 1	0.038 0	0.015 2	0.099 9	不确定
2	$\gamma_1$	0.004 9	0.705 4	0.128 5	0.143 2	0.018 0	不确定
3	$\gamma_2$	0.041 3	0.023 8	0.802 1	0.034 2	0.098 6	$\gamma_2$
4	$\gamma_3$	0.012 4	0.824 5	0.068 5	0.079 6	0.015 0	$\gamma_1$

表 2 证据体  $E_2$  单独作用下的基本可信度和诊断结果

序号	故障类别	$M(u_0)$	$M(u_1)$	$M(u_2)$	$M(u_3)$	$M(\Phi)$	诊断结论
1	$\gamma_0$	0.595 6	0.286 7	0.013 4	0.009 4	0.094 9	不确定
2	$\gamma_1$	0.135 3	0.601 2	0.128 8	0.083 6	0.051 1	不确定
3	$\gamma_2$	0.049 6	0.124 5	0.111 6	0.056 4	0.657 9	不确定
4	$\gamma_3$	0.015 7	0.017 9	0.206 1	0.648 7	0.111 6	不确定

表 3 证据体  $E_3$  单独作用下的基本可信度和诊断结果

序号	故障类别	$M(u_0)$	$M(u_1)$	$M(u_2)$	$M(u_3)$	$M(\Phi)$	诊断结论
1	$\gamma_0$	0.685 3	0.114 5	0.116 4	0.074 1	0.009 7	不确定
2	$\gamma_1$	0.015 3	0.813 2	0.062 4	0.024 2	0.084 9	$\gamma_1$
3	$\gamma_2$	0.024 3	0.864 1	0.014 5	0.034 2	0.9270	$\gamma_2$
4	$\gamma_3$	0.085 2	0.164 7	0.058 4	0.653 1	0.038 6	不确定

表 4 证据体  $E_4$  单独作用下的基本可信度和诊断结果

序号	故障类别	$M(u_0)$	$M(u_1)$	$M(u_2)$	$M(u_3)$	$M(\Phi)$	诊断结论
1	$\gamma_0$	0.601 2	0.125 6	0.108 9	0.075 2	0.089 1	不确定
2	$\gamma_1$	0.014 9	0.856 3	0.059 4	0.034 2	0.035 2	$\gamma_1$
3	$\gamma_2$	0.016 7	0.065 4	0.521 3	0.354 2	0.042 4	不确定
4	$\gamma_3$	0.090 1	0.134 3	0.062 3	0.672 1	0.041 2	不确定

表 5 融合诊断结果

序号	故障类别	$M(u_0)$	$M(u_1)$	$M(u_2)$	$M(u_3)$	$M(\Phi)$	诊断结论
1	$\gamma_0$	0.813 1	0.034 2	0.035 2	0.013 4	0.104 1	$\gamma_0$
2	$\gamma_1$	0.032 3	0.903 2	0.023 4	0.032 4	0.008 7	$\gamma_1$
3	$\gamma_2$	0.042 1	0.014 2	0.894 3	0.044 4	0.0050	$\gamma_2$
4	$\gamma_3$	0.056 4	0.025 3	0.021 4	0.884 2	0.012 7	$\gamma_3$

5 结束语

为了实现航天发动机故障诊断,文中设计了一种基于灰色模型-KFMC 和 DS 证据理论的飞机发动机故障诊断方法。

首先采用灰色模型根据传感器采集的历史数据对其在下一时刻的数据进行预测,在此基础上采用 KFMC 模糊聚类模型对预测数据所属的各分类进行预测,得到其所属各分类的权值,作为其所属故障的基本可信度分配,然后采用 DS 融合规则基于多个传感器预测的数据即证据进行诊断结果融合。

通过仿真实验证明了文中方法能有效地对飞机发动机进行故障诊断。

参考文献:

[1] Millott T A. Risk reduction flight test of a pre-production active vibration control system for the UH-60M[C]//American Helicopter Society 59th annual forum. Phoenix, USA:[ s. n. ], 2003.

[2] 王修岩,薛斌斌,李宗帅. 基于 Petri 网的飞机交流发电机故障诊断系统研究[J]. 中国民航大学学报,2012,30(1): 23-25.

[3] Vignal B, Krysinski T. Development and qualification of active vibration control system for the Eurocopter EC225/EC725 [C]//American helicopter society 61st annual forum. Grapevine, USA:[ s. n. ], 2005.

[4] 鲁 峰,黄金泉,陈 煜. 航空发动机部件性能故障融合诊

(下转第 138 页)

普查数据的二次加工和深度分析。

#### 4 结束语

在介绍水利普查数据特征的基础上,文中提出了适用于高维水利普查数据分析的部分物化立方体结构—HDEFC,以具有代表性的水电站工程数据为例,就 HDEFC 的生成算法、查询算法和立方体片段大小选择进行了探究,并构建了水利普查数据分析系统。此系统能够满足对水利普查数据分析的基本要求,且数据分析查询响应速度快于一般数据仓库的多维数据分析系统。通过实验进一步验证了提出的 HDEFC 方法在水利普查数据分析领域的适用性。相比于目前数据分析系统中普遍采用的低维度少度量的处理方式,得益于 HDEFC 的底层立方体结构和相应的查询方式,可以灵活地进行高维多度量的查询和分析,为水利决策者提供了更加广阔的数据视野。

#### 参考文献:

- [1] 庞进武,程益联,罗志东.水利普查与信息化[J].水利信息化,2012(1):19-22.
  - [2] 占军,万定生,李宇.基于 Oracle 数据仓库的水利普查数据展现系统[J].计算机与数字工程,2012,40(10):55-57.
  - [3] 杨嘉杰.水量水费数据立方体的 OLAP 和数据挖掘技术研究[D].广州:中山大学,2012.
  - [4] 尹涛,关兴中,万定生.数据挖掘技术在水文数据分析中的应用[J].计算机工程与设计,2012,33(12):4721-4725.
  - [5] Chaudhuri S, Dayal U. An overview of data warehousing and OLAP technology[J]. ACM SIGMOD Record, 1997, 26(1): 65-74.
  - [6] Ho C T, Agrawal R, Megiddo N, et al. Range queries in OLAP data cubes[J]. ACM SIGMOD Record, 1970, 26(2): 73-88.
  - [7] Gray J, Chaudhuri S, Bosworth A, et al. Data cube: a relational aggregation operator generalizing group-by, cross-tab, and sub-totals[J]. Data Mining and Knowledge Discovery, 1997, 1: 29-53.
  - [8] Markl V, Ramsak F, Bayer R. Improving OLAP performance by multidimensional hierarchical clustering [C]//Proc of IDEAS'99. [s. l.]: [s. n.], 1999: 165-177.
  - [9] 胡孔法,董逸生,徐立臻,等.一种基于维层次编码的 OLAP 聚集查询算法[J].计算机研究与发展,2004,41(4):608-614.
  - [10] 林俊鸿,姜琨,杨岳湘.倒排索引查询处理技术[J].计算机工程与设计,2015,36(3):572-575.
  - [11] 朱凯,万定生,程习锋.水利普查成果分析中数据立方体计算研究[J].计算机与数字工程,2014,42(9):1591-1594.
  - [12] Fang M, Shivakumar N, Garcia-Molina H, et al. Computing iceberg queries efficiently [C]//International conference on very large databases. New York: [s. n.], 1999.
  - [13] Li X, Han J, Gonzalez H. High-dimensional OLAP: a minimal cubing approach [C]//Proceedings of the thirtieth international conference on very large data bases. [s. l.]: [s. n.], 2004: 528-539.
  - [14] Li C, Cong G, Tung A K H, et al. Incremental maintenance of quotient cube for median [C]//Proceedings of the tenth ACM SIGKDD international conference on knowledge discovery and data mining. Washington: ACM, 2004: 226-235.
- 
- (上接第 133 页)
- 断方法研究[J].航空动力学报,2009,24(7):1649-1653.
  - [5] Blackwell R, Millott T. Dynamic design characteristics of the Sikorsky X2 technology demonstrator aircraft [C]//American helicopter society 65th annual forum. Montreal, Canada: [s. n.], 2008.
  - [6] 周虹,左洪福,蔡景,等.基于 TMSDG 的民用飞机故障诊断隔离策略[J].航空学报,2012,33(3):479-486.
  - [7] 陈晓,马建仓.基于 MEL 倒谱的某型飞机发动机振动故障的模式识别[J].计算机测量与控制,2012,20(8):2028-2030.
  - [8] 马建仓,刘小龙,陈静.二代小波降噪与盲分离结合应用于航空发动机振动信号分析[J].机械科学与技术,2010,29(1):7-11.
  - [9] 戴敏,谢椿.基于模糊加权有色网和 BP 神经网络的飞机发动机故障诊断[J].科学技术与工程,2012,12(35):9552-9556.
  - [10] 赵鹏,蔡忠春,李晓明,等.某型飞机发动机故障诊断专家系统设计[J].计算机测量与控制,2014,22(12):3850-3852.
  - [11] 于霞,张卫民,邱忠超,等.飞机发动机叶片缺陷的差激励涡流传感器检测[J].北京航空航天大学学报,2015,41(9):1582-1588.
  - [12] 黄强,王健,张桂刚.一种航空发动机传感器故障诊断方法[J].传感技术学报,2014,27(10):1315-1320.
  - [13] 李业波,李秋红,黄向华,等.航空发动机气路部件故障融合诊断方法研究[J].航空学报,2014,35(6):1612-1622.
  - [14] Blachnio J. Capabilities to assess health/maintenance status of gas turbine blades with non-destructive methods [J]. Polish Maritime Research, 2015, 21(4): 41-47.