

基于 CKF-LSTM 的燃气轮机气路故障诊断研究

康宇航, 曹云鹏, 李淑英

(哈尔滨工程大学 动力与能源工程学院, 哈尔滨 150001)

Study on Gas Path Fault Diagnostic for Gas Turbine based on CKF-LSTM

KANG Yuhang, CAO Yunpeng, LI Shuying

(College of Power and Energy Engineering, Harbin Engineering University, 150006, Harbin)

Abstract: A multi-model gas turbine fault diagnosis method based on Cubature Kalman Filters-Long Short-term Memory CKF-LSTM is proposed, which integrates the advantages of model-based and data-driven. A priori fault state estimation model is established with volumetric Kalman filter to extract the residual feature of operating state. LSTM neural network is used to identify residuals of former residence models with multiple prior states at the same time to realize gas path fault diagnosis. The proposed method is tested by using typical fault simulation data of heavy-duty gas turbine. The verification results show that the gas path fault diagnosis method based on CKF-LSTM has good diagnostic accuracy, and the fault diagnosis accuracy is higher than 95.6% at the three working conditions of heavy-duty gas turbine.

摘要:提出了基于容积卡尔曼滤波-长短期记忆网络(Cubature Kalman Filters - Long Short-term Memory CKF-LSTM)的多模型燃气轮机气路故障诊断方法,该方法集成了基于模型和数据驱动的优点。使用容积卡尔曼滤波器建立先验故障状态估计模型,提取运行状态残差特征;采用 LSTM 神经网络同时对多个先验状态故障模型残差特征进行识别,实现气路故障的诊断。利用重型燃气轮机典型故障仿真数据对所提出的方法进行测试,验证结果表明:基于 CKF-LSTM 的燃气轮机气路故障诊断方法具有良好的诊断准确性,在重型燃气轮机 3 个工况点的故障诊断准确率均高于 95.6%。

关键词:重型燃气轮机;故障诊断;卡尔曼滤波器;神经网络;多模型

Key words: heavy-duty gas turbine; fault diagnosis; kalman filter; neural network; multi-model

中图分类号: TK478

文献标识码: A

0 概述

我国作为能源消耗大国在天然气发电领域的规模增长较快。天然气资源大量开发、不断增长的电网调峰需求与分布式能源系统的飞速发展,都决定着重型燃气轮机在我国发电领域的重要地位。重型燃气轮机的系统不断复杂化,其工作环境又极其恶劣、工况变化迅速、运行时间长,其失效风险大大增加。由于电站重型燃气轮机的特殊性,燃气轮机如果发生故障不仅会导致其性能下降,也影响着整个电力系统的稳定,可能造成巨大的经济损失^[1-2]。燃气轮机的故障诊断,即故障检测和隔离可以

为实现燃机视情维修提供支持,尽力避免因停机或中断带来的经济损失。

故障诊断方法主要分为三类:基于模型、基于数据驱动和基于混合的方法^[3]。基于模型的故障诊断方法它需要根据设备的工作机理,建立能够表征设备故障规律的数学模型。近年快速发展的人工智能技术能够解决基于模型方法的部分实际计算问题,但是每一个实际系统均存在其独特性,可能面临着某些局限性。基于数据驱动的故障诊断方法不需要建立数学或物理模型,对于先验知识也相应的没有严格的要求,直接使用采集的设备相关参数,

收稿日期: 2023-07-30

基金项目: 船舶动力基础科研项目(KY10300210082)

作者简介: 康宇航(1999-),男,硕士生,主要研究方向为燃气轮机装置故障诊断与健康管管理, E-mail: kyh@hrbeu.edu.cn;
曹云鹏(联系人), E-mail: caoyunpeng@hrbeu.edu.cn。

对数据进行分析和处理, 获得可以表征设备性能变化的关键特征, 从而实现故障诊断。混合机构故障诊断方法可以集成基于模型和数据驱动的优点, 组合不同方法实现准确故障诊断。

故障检测与隔离方法中多模型架构是一种可以将结合数据驱动和基于模型的混合架构。在燃气轮机相关领域, Maybeck^[4]针对燃气轮机执行器与传感器故障的诊断, 应用多模型方法实现了传感器或执行器单故障诊断。Sadough 等^[5]利用多模型架构融合卡尔曼滤波与贝叶斯方法, 最终实现燃气轮机气路故障的准确诊断。Pourbabae 等^[6]结合多模型与混合卡尔曼滤波方法, 基于软切换方法实现燃气轮机全工况的传感器故障诊断。Meskin^[7]等是把多模型方法用于燃气轮机气路故障诊断的首个团队, 提出一种模块化、层次化结构, 燃气轮机故障诊断是通过最大概率准则实现。Yang 等^[8]将多模型方法与强跟踪卡尔曼滤波器相结合用于燃气轮机气路故障诊断, 该方法对于燃气轮机模型具有鲁棒性。

混合故障诊断方法能够解决基于模型与数据驱动方法实现过程中的一些问题, 比如基于模型方法中精确系统模型建立困难, 数据驱动方法需要大量故障数据。Darooqeh 等^[9]将神经网络与粒子滤波方法结合提出一种燃气轮机健康状态预测方法。Chao 等^[10]研究了一种基于深度学习算法和物理模型的混合故障诊断架构, 并使用 N-CMAPSS 数据集对改方法验证。王启航等^[11]针对复杂噪声情况下燃气轮机气路故障诊断困难的问题, 提出一种基于变分贝叶斯和核极限学习机的边缘化粒子滤波方法。

综合上述研究可以看出, 集成基于模型和数据驱动方法的混合方法已经成为当前的研究热点。本文提出一种混合故障诊断方法, 基于多模型架构融合容积卡尔曼滤波器组 (Cubature Kalman Filters, CKFs) 和长短时记忆网络 (Long Short-term Memory, LSTM), 使用 CKF 构建燃气轮机正常状态和先验故障状态估计模型, 采用 LSTM 方法利用先验状态估计模型输出与实际数据的残差实现燃气轮机智能气路故障诊断。

1 气路故障诊断方法

1.1 基于 CKF-LSTM 的故障诊断方法

在多模型方法基础上使用非线性滤波器-容积卡尔曼滤波器建立燃气轮机热力参数先验状态估计

模型, 加入有监督分类器-LSTM 神经网络作为模式识别算法, 保障了本方法的故障诊断精度。在线故障诊断方法的总体架构如图 1 所示, N 表示模型数量, 包含健康模型和故障模型。整体架构由带燃气轮机仿真模型、多模型架构的 CKF 估计模型和 LSTM 诊断模块组成。

本文提出的基于 CKF-LSTM 的故障诊断方案由两个主要部分组成, 即故障状态数据在线估计的先验状态估计模型和用于故障诊断的 LSTM 神经网络。利用仿真数据使用系统参数辨识建模方法建立燃气轮机热力参数间的非线性数学模型, 包括正常模型和进气滤网积垢、压气机叶片积垢、叶片腐蚀、叶顶间隙等四种故障模型。

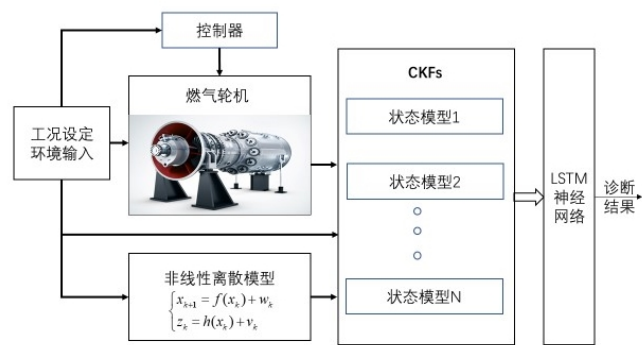


图 1 基于 CKF-LSTM 的多模型气路故障诊断方法架构

使用容积卡尔曼滤波器构建正常状态估计模型和先验故障状态估计模型, 每一种状态估计模型对应一种状态下监测数据的在线估计。构建实时监测数据与各种先验故障状态估计参数的残差, 当燃气轮机发生某种故障时, 该状态估计与实时数据残差趋近于零。使用监督分类器根据残差进行诊断, 分类器是预先使用带标签的残差数据进行训练并经过检验的。

1.2 基于多模型架构的容积卡尔曼滤波器组

对于任意假设模型, 考虑带高斯白噪声的非线性系统为:

$$\begin{cases} x_{k+1} = f(x_k) + w_k \\ z_k = h(x_k) + v_k \end{cases} \quad (1)$$

式中, $x_k \in R^n$ 和 $z_k \in R^m$ 分别为 k 时刻系统 n 维状态向量和 m 维量测向量; $f(\cdot)$ 和 $h(\cdot)$ 为系统非线性状态函数和量测函数; 系统噪声 w_k 与量测噪声 v_k 分别是均值为零, 协方差为 Q_k 和 R_k 的互不相关的高斯白噪声。

对于标准的高斯分布有:

$$I(f) = \int_{R^n} f(x)N(x; \mathbf{0}, I)dx \approx \sum_{i=1}^m w_i f(\xi_i) \quad (2)$$

式中, $\xi_i = \sqrt{\frac{m}{2}} [\mathbf{1}]_i$; $w_i = \frac{1}{m}$; $m = 2n$ 。式(2)

就是容积卡尔曼滤波使用的三阶球面相径容积规则。

CKF 算法流程如下:

1) 滤波初始化

$$\begin{cases} \hat{x}_{0|0} = E(x_0) \\ P_{0|0} = E(x_0 - \hat{x}_{0|0})(x_0 - \hat{x}_{0|0})^T \end{cases} \quad (3)$$

2) 时间更新

假设 k 时刻状态 x_k 的统计特性为 $N(x_k; \hat{x}_{k|k}, P_{k|k})$, 求取容积点为:

$$\alpha_i' = S_{k|k} \xi_i + \hat{x}_{k|k}, i = 1, 2, \dots, m \quad (4)$$

式中, $m = 2n$, n 为状态变量的维数;

$P_{k|k} = S_{k|k} S_{k|k}^T$; ξ_i 为第 i 个容积点, 由式(3) 可以求得。

容积点经过状态非线性函数传递为:

$$\gamma_{k+1|k}^i = f(\alpha_i') \quad (5)$$

一步状态预测和方差为:

$$\hat{x}_{k+1|k} = \frac{1}{m} \sum_{i=1}^m \gamma_{k+1|k}^i \quad (6)$$

$$P_{k+1|k} = \frac{1}{m} \sum_{i=1}^m \gamma_{k+1|k}^i (\gamma_{k+1|k}^i)^T - \hat{x}_{k+1|k} \hat{x}_{k+1|k}^T + Q_k \quad (7)$$

3) 量测更新

将状态预测估计方差 $P_{k+1|k}$, 进行 *Cholesky* 分解可得: $P_{k+1|k} = S_{k+1|k} S_{k+1|k}^T$, 相应的容积点可以求取为:

$$\eta_i' = S_{k+1|k} \xi_i + \hat{x}_{k+1|k}, i = 1, 2, \dots, m \quad (8)$$

经过非线性量测函数的传递得:

$$\eta_{k+1|k}^i = h(\eta_i') \quad (9)$$

量测一步预测、方差以及互协方差为:

$$\hat{z}_{k+1|k} = \frac{1}{m} \sum_{i=1}^m \eta_{k+1|k}^i \quad (10)$$

$$P_{zz, k+1|k} = \frac{1}{m} \sum_{i=1}^m \eta_{k+1|k}^i (\eta_{k+1|k}^i)^T - \hat{z}_{k+1|k} \hat{z}_{k+1|k}^T + R_{k+1} \quad (11)$$

$$P_{xz, k+1|k} = \frac{1}{m} \sum_{i=1}^m \gamma_{k+1|k}^i (\eta_{k+1|k}^i)^T - \hat{x}_{k+1|k} \hat{z}_{k+1|k}^T \quad (12)$$

滤波增益 $k+1$ 时刻的状态估计和估计方差为:

$$\begin{cases} \hat{x}_{k+1|k+1} = \hat{x}_{k+1|k} + K_{k+1} (z_{k+1} - \hat{z}_{k+1|k}) \\ K_{k+1} = P_{xz, k+1|k} (P_{zz, k+1|k})^{-1} \\ P_{k+1|k+1} = P_{k+1|k} - K_{k+1} P_{zz, k+1|k} K_{k+1}^T \end{cases} \quad (13)$$

基于多模型架构的容积卡尔曼滤波器组如图 1 中 CKFs 部分所示, 根据系统故障先验知识, 建立表征系统可能状态的假设模型, 包括正常状态以及不同故障状态, 通过对每个假设模型设计卡尔曼滤波器进行并行滤波估计, 得到第 j 个模型中卡尔曼滤波器产生的测量估计残差 $\gamma(j)$ 当燃气轮机发生某种故障时, 该状态估计与实时数据残差趋近于零。

1.3 LSTM 模式识别

LSTM (长短时记忆网络) 是由循环神经网络 (Recurrent Neural Network, RNN) 经过改进而来的, 是一种神经网络, 其算法结构有多个类似环结构的神经元相连接是其与一般神经网络显著的区别。LSTM 网络模型中隐藏层与隐藏层之间存在权重连接, 同一隐藏层内部包含的不同神经元中各结构之间也存在连接。LSTM 内部的储存和循环结构决定了它在处理时序输入数据的独特优越性。因此, LSTM 网络常被用于时序数据的故障诊断。

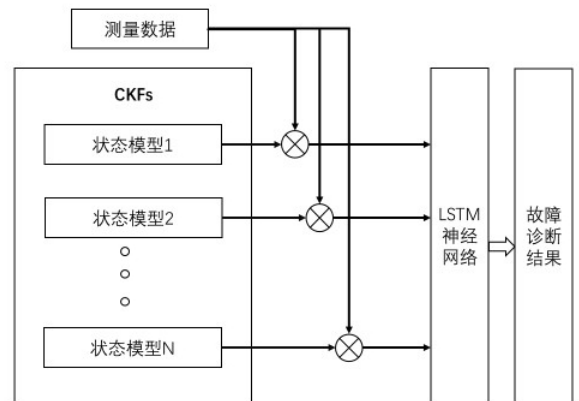


图 2 LSTM 网络训练

由于燃气轮机建模、状态估计模型建立等环节均存在误差, 误差的累积可能导致测量估计残差输出结果不太理想, 因此本文使用 LSTM 神经网络根据残差结果实现故障诊断。LSTM 的离线训练过程如图 2 所示, 网络的输入为非线性状态估计模型输出与燃气轮机测量值的残差, 输出为燃气轮机故障诊断结果。LSTM 训练目标是为了最小化均方误差

代价函数。

2 仿真验证

2.1 燃气轮机故障仿真

本节以 9FA 重型燃气轮机为研究对象，采用模块法，分部件建立燃气轮机非线性动态模型。燃气轮机部件之间是依据气动、热力学定律，并按照部件之间的共同工作关系建立的动态模型，满足流量平衡、功率平衡及质量平衡等基本方程，给定输入量经过复杂的迭代计算得到模型计算输出。

模型输入包括：环境输入、功率要求、性能参数输入。该模型可以模拟重型燃气轮机常见的压气机叶片积垢、叶片腐蚀、叶顶间隙等故障。根据先验知识，各典型故障模式判据如下表所示：

表 1 典型故障模式判据

故障模式	判据
F1 进气滤网积垢	进气滤网压损系数降低 5%
F2 叶片磨损/腐蚀	压气机效率降低 2%
F3 叶片积垢	压气机流量降低 7%，压气机效率降低 2%
F4 叶片顶隙故障	压气机流量降低 4%，压气机效率降低 1.8%

根据典型故障模式判据，以实际运行数据的环境温度 T_0 、大气压力 P_0 等外界条件为模型输入，利用仿真模型对 0.61、0.72、0.94 工况下运行数据进行故障仿真，生成典型故障模式的数据，将健康数据与故障数据共同组成数据样本集。下图展示了 0.61-0.72-0.94 工况下部分仿真故障数据，为了将故障模式与健康模式进行对比，以不同故障模式与健康状态相对值进行展示，如图 3 所示。

建立的燃气轮机气路故障诊断数据集，包括 0.61、0.72、0.94 工况，进气滤网积垢、叶片磨损/腐蚀、叶片积垢和叶片顶隙四个典型故障，每个工况各典型故障包含 1000 组样本，该数据集为后续热力性能故障诊断提供了数据基础。

2.2 气路故障估计模型建立

使用上述模型得到燃气轮机的正常、压气机叶片积垢、叶片腐蚀、压气机进气压损及叶顶间隙故障的仿真数据。依据系统辨识建模方法，根据经验推导参数之间的关系模型阶次为二阶，使用参数辨识得到模型参数，至此就建立了燃气轮机热力参数间的非线性数学模型。采用容积卡尔曼滤波器(CKF)构建正常状态估计模型和先验故障状态估计模型，

非线性滤波器估计模型输出与真实数据对比如图 4 所示，横轴为样本数，纵轴为估计模型输出与真实数据归一化之后的结果。估计模型输出的四个参数综合均方根误差 (RMSE) 为 0.002。

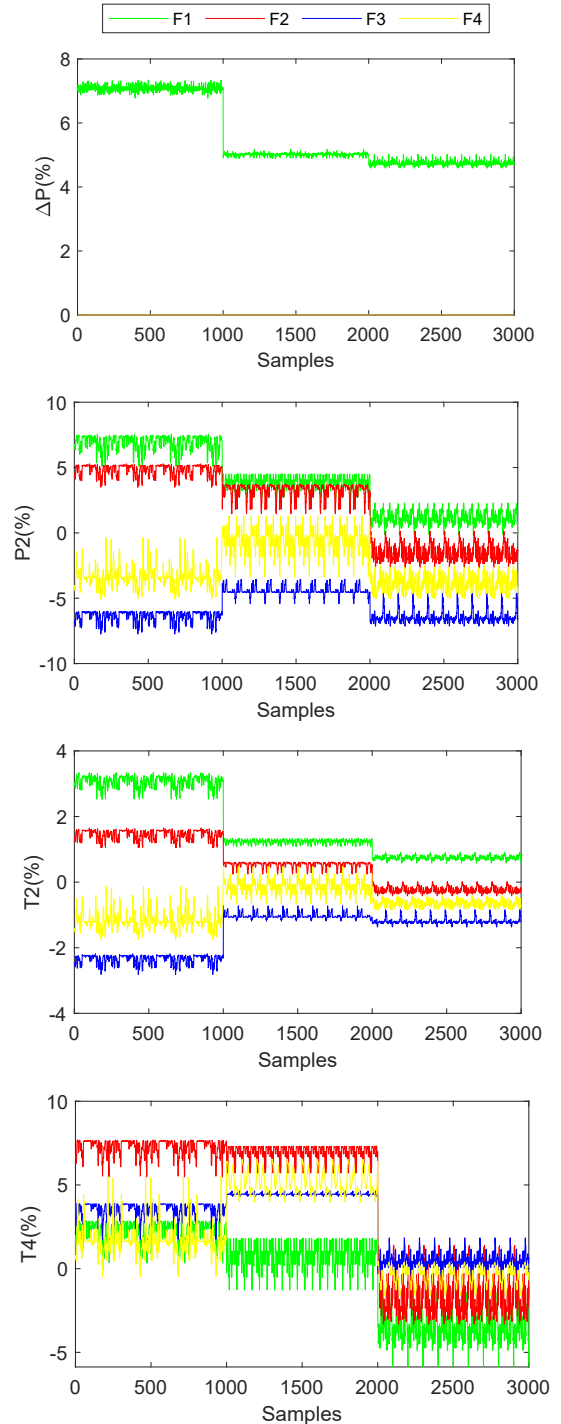





图 3 燃气轮机气路故障诊断数据集




a. 压气机进气压损



b. 压气机出口压力



c. 压气机出口温度



d. 透平出口温度

图4 容积卡尔曼滤波器估计结果

2.3 气路故障诊断结果

故障诊断时，构建实时监测数据与各种先验故障状态估计参数的残差，当燃气轮机发生某种故障时，该状态估计与实时数据残差趋近于零。但由于各个环节均存在误差，误差累积导致实际结果不太理想，因此本文使用监督分类器根据残差结果进行诊断。监督分类器是预先使用带标签的残差数据进行训练的，分别使用三个稳态工况的残差数据训练 LSTM 神经网络，训练结果如图 5-图 7 所示。




图5 LSTM 神经网络模型训练结果（0.61 工况）




图6 LSTM 神经网络模型训练结果（0.72 工况）

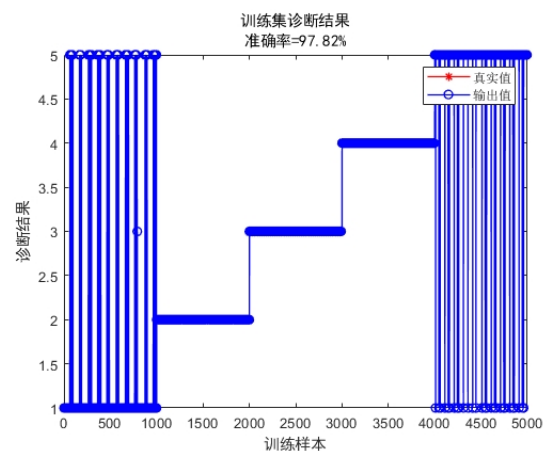


图7 LSTM 神经网络模型训练结果（0.94 工况）

如图 5-7 所示, 三种稳态工况下 LSTM 神经网络模型对于训练集故障诊断结果准确率高于 94.14%。然后使用训练的 LSTM 网络模型对测试集数据进行诊断, 测试结果如图 8-图 10 所示

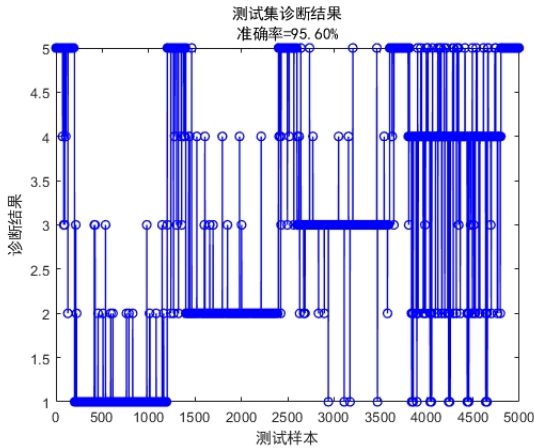


图 8 LSTM 网络模型测试诊断结果 (0.61 工况)




图 9 LSTM 网络模型测试诊断结果 (0.72 工况)




图 10 LSTM 网络模型测试诊断结果 (0.94 工况)

从测试结果图 9-图 11 可知, 提出的基于多模型的燃气轮机气路故障诊断方法在 0.72 工况的气路故障诊断结果最好准确率达到 100%; 0.94 工况的气路故障诊断准确率为 97.62%, 错误主要集中在故障 1 即压气机叶片腐蚀故障误判为正常; 0.61 工况

的气路故障诊断结果为 95.6%。因此, 在重型燃气轮机 3 个工况点, 气路故障诊断方法的故障检测率均高于 95.6%, 为工程实际应用提供参考。

3 结论

提出了一种基于多模型架构融合容积卡尔曼滤波器组和长短时记忆网络的混合故障诊断方法, 采用容积卡尔曼滤波器 (CKF) 构建正常状态估计模型和先验故障状态估计模型, 估计模型输出的四个参数综合均方根误差 (RMSE) 为 0.002, 满足精度要求。对于燃气轮机建模、状态估计模型建立等环节均存在误差, 误差的累积可能导致测量估计残差输出结果不太理想, 本文使用 LSTM 神经网络根据残差结果实现故障诊断。基于 CKF-LSTM 的多模型燃气轮机气路故障诊断方法对燃气轮机四种典型气路故障诊断准确率高于 95.6%, 能够实现燃气轮机不同故障类型的准确诊断。

参考文献:

- [1] 翁一武, 闻雪友, 翁史烈. 燃气轮机技术及发展[J]. 自然杂志, 2017, 39: 43~47.
- [2] 刘帅, 刘玉春. 重型燃气轮机发展现状及展望[J]. 电站系统工程, 2018, 34(05): 65-67.
- [3] Tahan M, Tsoutsanis E, Muhammad M, et al. Performance-Based Health Monitoring, Diagnostics and Prognostics for Condition-Based Maintenance of Gas Turbines: A Review[J]. Applied Energy, 2017, 198: 122-144.
- [4] Maybeck P S. Multiple Model Adaptive Algorithms for Detecting and Compensating Sensor and Actuator/Surface Failures in Aircraft Flight Control Systems[J]. International Journal of Robust and Nonlinear Control, 1999, 9(14): 1051-1070.
- [5] Sadough Vanini Z N, Meskin N, Khorasani K. Multiple-Model Sensor and Components Fault Diagnosis in Gas Turbine Engines Using Autoassociative Neural Networks[J]. Journal of Engineering for Gas Turbines and Power, 2014, 136 (9) .
- [6] Pourbabaee B, Meskin N, Khorasani K. Sensor Fault Detection, Isolation, and Identification Using Multiple-Model-Based Hybrid Kalman Filter for Gas Turbine Engines[J]. IEEE Transactions on Control Systems Technology, 2015, 24 (4) : 1184-1200.
- [7] Meskin N, Naderi E, Khorasani K. A Multiple Model-based

-
- Approach for Fault Diagnosis of Jet Engines[J]. Control Systems Technology IEEE Transactions on, 2013, 21(1): 254-262.
- [8] Yang Q, Li S, Cao Y. Multiple Model-Based Detection and Estimation Scheme for Gas Turbine Sensor and Gas Path Fault Simultaneous Diagnosis[J]. Journal of Mechanical Science and Technology, 2019, 33 (4) : 1959- 1972.
- [9] Daroogheh N, Baniamerian A, Meskin N, et al. Prognosis and Health Monitoring of Nonlinear Systems Using a Hybrid Scheme Through Integration of PFs and Neural Networks[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2016, 47(8): 1990-2004.
- [10] Chao M A, Kulkarni C, Kai G, et al. Hybrid Deep Fault Detection and Isolation: Combining Deep Neural Networks and System Performance Models[J]. International Journal of Prognostics and Health Management, 2020,10: 1-19.
- [11]王启航, 黄金泉, 鲁峰. 基于变分贝叶斯粒子滤波的航空发动机气路故障诊断方法 [J]. 机械制造与自动化, 2022, 51(2): 181-185.
- [12] I. Arasaratnam, S. Haykin. Cubature Kalman filters[J]. IEEE Transactions on Automatic Control, 2009, 54(6): 1254-1269P.