

# 基于多模型的航空发动机传感器混合故障诊断方法\*

赵万里<sup>1</sup>, 郭迎清<sup>1</sup>, 徐柯杰<sup>1</sup>, 杨庆材<sup>2</sup>, 王 昆<sup>1</sup>, 郭鹏飞<sup>1</sup>

(1. 西北工业大学 动力与能源学院, 陕西 西安 710129;

2. 杭州汽轮动力集团股份有限公司, 浙江 杭州 310022)

**摘要:** 本文在多模型架构下, 提出一种航空发动机传感器在线混合故障检测与隔离算法。利用长短期记忆网络逼近航空发动机建模误差、健康参数变化、过程噪声和测量噪声等不确定性源引起的真实发动机与机载模型之间的偏差。将传感器测量输出与不确定性值的偏差用于一种基于多模型的混合卡尔曼滤波器组算法中, 利用贝叶斯方法计算每个传感器在健康模式和不同故障模式下的条件概率, 然后根据最大概率准则进行传感器故障检测与隔离, 克服了阈值难以选取的问题。针对某型涡扇发动机传感器发生偏置故障、漂移故障和间歇性故障的情形进行仿真验证, 并对比了不同传感器之间的检测与隔离精度。结果表明: 所提出的方法可以在更高水平的退化下诊断出发动机传感器常见的故障, 混合方法对不同不确定性源具有鲁棒性。

**关键词:** 航空发动机; 传感器; 多模型; 故障诊断; 长短期记忆网络; 混合卡尔曼滤波

**中图分类号:** V233.7 **文献标识码:** A **文章编号:** 1001-4055 (2023) 03-2208021-09

**DOI:** 10.13675/j.cnki.tjjs.2208021

## Hybrid Fault Diagnosis Method for Aero-Engine Sensor Based on Multiple Model

ZHAO Wan-li<sup>1</sup>, GUO Ying-qing<sup>1</sup>, XU Ke-jie<sup>1</sup>, YANG Qing-cai<sup>2</sup>, WANG Kun<sup>1</sup>, GUO Peng-fei<sup>1</sup>

(1. School of Power and Energy, Northwestern Polytechnical University, Xi'an 710129, China;

2. Hangzhou Steam Turbine Co., Ltd, Hangzhou 310022, China)

**Abstract:** Under the multi-model architecture, an online hybrid fault detection and isolation algorithm for aero-engine sensor is proposed. The long short-term memory network is used to approximate the deviation between the real engine and the on-board engine model caused by the uncertainty sources such as aero-engine modelling error, health parameter changes, process noise and measurement noise. The deviation between the sensor measurement output and the uncertainty value is used in a hybrid Kalman filters algorithm based on multiple model method. The Bayesian approach is used to calculate the conditional probability of each sensor under health mode and different fault modes, and then the maximum probability criterion is used for sensor fault detection and isolation to overcome the problem of difficult threshold selection. The simulation is carried out to verify the sensor bias fault, drift fault and intermittent fault of a turbofan engine, and the detection and isolation accuracy of different sensors is compared. The results show that the proposed method can diagnose common faults of aero-engine sensor at higher levels of degradation, and the hybrid method is robust to different sources of uncertainty.

\* 收稿日期: 2022-08-09; 修订日期: 2022-10-24。

基金项目: 国家科技重大专项 (J2019-V-0003-0094)。

作者简介: 赵万里, 博士生, 研究领域为航空发动机故障诊断与健康管。

通讯作者: 郭迎清, 博士, 教授, 研究领域为航空发动机先进控制技术和健康管理技术。E-mail: yqguo@nwpu.edu.cn

引用格式: 赵万里, 郭迎清, 徐柯杰, 等. 基于多模型的航空发动机传感器混合故障诊断方法[J]. 推进技术, 2023, 44(3): 2208021. (ZHAO Wan-li, GUO Ying-qing, XU Ke-jie, et al. Hybrid Fault Diagnosis Method for Aero-Engine Sensor Based on Multiple Model[J]. *Journal of Propulsion Technology*, 2023, 44(3):2208021.)

**Key words:** Aero-engine; Sensor; Multiple model; Fault diagnosis; Long short-term memory; Hybrid Kalman filter

## 1 引言

在现代航空工业中,由于对安全关键系统的可靠运行和可维护性的需求和要求越来越高,航空发动机的故障诊断,即故障检测和隔离引起了广泛关注。航空发动机故障诊断技术可以避免因停机或中断而造成的重大经济损失,以及不及时和不必要地更换部件和零件相关的成本,与传统的基于时间的维护相比,航空发动机的故障诊断能够为实现视情维修的决策提供技术支持。视情维修是以系统的实际情况为依据来维修或者更换部件的一种维修策略<sup>[1-2]</sup>。因此,故障诊断方法的不断发展和实施可以显著减少由系统故障引起的经济损失。

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<sup>[3]</sup>。基于模型的方法主要依赖系统的数学模型,在实时状态监测方面具有很大的应用前景,但是由于系统中存在不确定性,未建模动态和干扰等因素,并且随着系统复杂性的增加,建立精确的数学模型往往比较困难。数据驱动的方法则需要大量的历史数据或实时数据,不需要系统的详细数学模型。尽管人工智能系统对于解决基于模型方法中的实际计算问题很重要,但每一个系统都面临某些特定的局限性。因此,使用混合架构将不同方法进行适当组合非常适合故障诊断<sup>[4]</sup>。

多模型方法是一种流行的故障检测与隔离(Fault Detection and Isolation, FDI)结构,可以将基于模型和基于数据的方法融合进行故障检测与隔离。在发动机相关领域中,Maybeck<sup>[5]</sup>最早将多模型方法应用于燃气轮机执行器故障与传感器故障检测与隔离,实现了传感器或执行器单故障及多故障的检测。Sadough等<sup>[6]</sup>则使用多模型方法将卡尔曼滤波方法与贝叶斯方法相结合,实现了气路故障的准确检测与隔离。Pourbabaee等<sup>[7]</sup>对多模型方法进行了拓展,将多模型方法与混合卡尔曼滤波方法结合对传感器故障进行检测与隔离,使用软切换方法实现了燃气轮机全工况下传感器故障检测与隔离。Yan等<sup>[8]</sup>提出一种基于无迹卡尔曼滤波器同时诊断燃气轮机气路和传感器故障诊断方法,在多模型架构下采用分层架构进行实现,使用一组加权平方和进行故障检测和隔离。Yang等<sup>[9]</sup>基于多模型架构,设计了一种基于强跟踪扩展卡尔曼滤波器的方法用于燃气轮机故障

诊断,该方法对模型不确定性具有鲁棒性,并且克服了多模型方法的缺点。

混合方法可以解决基于模型方法中系统模型难以建立和基于数据驱动方法中故障数据难获取的问题。Darogheh等<sup>[10]</sup>提出了一种基于粒子滤波和神经网络的燃气轮机健康状态预测方法。Chao等<sup>[11]</sup>将物理性能模型与深度学习算法相结合提出一种混合故障诊断框架,并在N-CMAPSS数据集中进行了验证。王启航等<sup>[12]</sup>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,实现了复杂噪声背景下发动机气路故障诊断。王召广等<sup>[13]</sup>针对涡轴发动机气路故障模式识别精度不高的问题,提出一种基于Relief-LMBP故障特征提取的发动机故障模式识别方法。

从上述研究现状可以看出,混合方法通过集成基于模型和数据驱动方法的优点,已成为当前研究热点和趋势。为此,本文提出一种混合智能故障诊断框架,基于多模型架构对混合卡尔曼滤波器组(Hybrid Kalman Filters, HKFs)和长短期记忆网络(Long Short-term Memory, LSTM)进行融合,利用LSTM方法逼近涡扇发动机建模误差、健康参数变化、过程噪声和测量噪声引起的不同不确定源,采用贝叶斯理论计算条件概率克服故障检测与隔离阈值难以选取的问题,最终依据概率最大准则进行故障检测与隔离,提高了故障诊断结果的置信度。

## 2 基于多模型的LSTM-HKFs混合故障诊断方法

### 2.1 基于LSTM-HKFs的混合故障诊断方法

基于模型的鲁棒故障诊断策略限制了对特定不确定性源的鲁棒性<sup>[14]</sup>。虽然可以通过应用混合方法来提高鲁棒性,但实际上不可能为所有不确定性源设计一个完全鲁棒的策略。本文在文献[15]的基础上,提出了一种混合式航空发动机模型,并将其与基于多模型的传感器FDI方法(使用HKFs库)相结合时,该模型提高了对不同类型建模不确定性的鲁棒性。

在这个问题中,假设实际航空发动机的离散时间无故障版本由式(1)给出

$$\begin{aligned} X(k+1) &= F(X(k), U(k), H(k), w(k)) \\ Y(k) &= G(X(k), U(k), H(k)) + v(k) \end{aligned} \quad (1)$$

式中  $X(k) \in \mathbf{R}^n$ ,  $Y(k) \in \mathbf{R}^q$ ,  $U(k) \in \mathbf{R}^p$ ,  $H(k) \in \mathbf{R}^r$ , 分别是真实的发动机状态变量、传感器测量值、控制输入和健康参数。发动机健康参数,即压气机和涡轮质量流量和效率是状态相关变量,在发动机寿命周期内,这些参数从其健康参考基线退化,取决于发动机压气机和涡轮性能图。此外,过程噪声和测量噪声也由  $w(k)$  和  $v(k)$  表示,被假定为分别应用于发动机环境参数和传感器测量的均值为0的高斯噪声信号。基于热力学定律为发动机设计的标称非线性机载发动机模型(On-board engine model, OBEM),定义如式(2)

$$\begin{aligned} X_{\text{OBEM}}(k+1) &= f(X_{\text{OBEM}}(k), U(k), H_{\text{OBEM}}(k)) \\ X_{\text{OBEM}}(0) &= X_{\text{OBEM}0} \\ Y_{\text{OBEM}}(k) &= g(X_{\text{OBEM}}(k), H_{\text{OBEM}}(k)) \end{aligned} \quad (2)$$

式中  $X_{\text{OBEM}}(k) \in \mathbf{R}^n$ ,  $Y_{\text{OBEM}}(k) \in \mathbf{R}^q$ ,  $H_{\text{OBEM}}(k) \in \mathbf{R}^r$  分别表示 OBEM 状态变量、系统输出和健康参数,由于不同的不确定性源和被忽略的动力学,这些变量与实际发动机变量不完全相同。事实上,不确定性会影响发动机建模过程,因此需要在实际发动机传感器测量中近似补偿不确定性的严重程度,以便在 FDI 方案中进一步使用。

为了逼近不确定性,本文提出了一种新的混合智能发动机建模方法。基于多模型架构,采用 LSTM 神经网络估计航空发动机性能退化和不确定性对传感器测量值的影响,基于航空发动机非线性模型和分段线性化模型开发观测器组来进行故障检测与隔离。通过使用离线训练的 LSTM 网络,混合卡尔曼滤波器组(HKF)被用来构造与 LSTM 集成的观测器组,将

LSTM 修正后的传感器测量值应用于滤波器组,以检测和隔离发动机传感器常见故障,在线混合智能 FDI 方法的总体架构如图 1 所示,  $L$  表示模型数量,包含健康模型和故障模型。混合架构由带控制器的实际发动机、估计不确定性的 LSTM 网络、OBEM 和多模型架构的 HKFs 诊断模块组成。

提出的基于 LSTM-HKF 混合 FDI 方案由两个主要部分组成,即用于估计不确定性影响的长短期记忆网络和一组利用修正测量值进行传感器故障检测和隔离的混合卡尔曼滤波器组。LSTM 是在无故障的情况下离线设计的,并用于基于多模型的在线 FDI 方案中,来估计由于模型不确定性和性能退化引起的输出误差  $\hat{Y}_{\text{un}}(k)$ 。LSTM 输出为不确定性项  $Y_{\text{un}}(k) = Y(k) - Y_{\text{OBEM}}(k)$ ,之后从实际发动机传感器测量值中删除,形成修改后的测量值,即  $Y_m(k) = Y(k) - \hat{Y}_{\text{un}}(k)$ 。最后,将修正后的传感器测量值  $Y_m(k)$  应用于一组 HKFs,采用多模型方案检测和隔离不同的传感器故障。

### 2.2 基于多模型架构的混合卡尔曼滤波器组

基于多模型架构的混合卡尔曼滤波器组故障诊断算法结构图如图 2 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混合卡尔曼滤波器进行并行滤波估计,得到第  $j$  个模型中混合卡尔曼滤波器产生的测量估计残差  $\gamma^{(j)}(k)$  和协方差矩阵  $S^{(j)}(k)$ ,递归计算各个假设模型的条件概率  $P_j$ ,并通过概率最大准则确定与当前运行状态最匹配

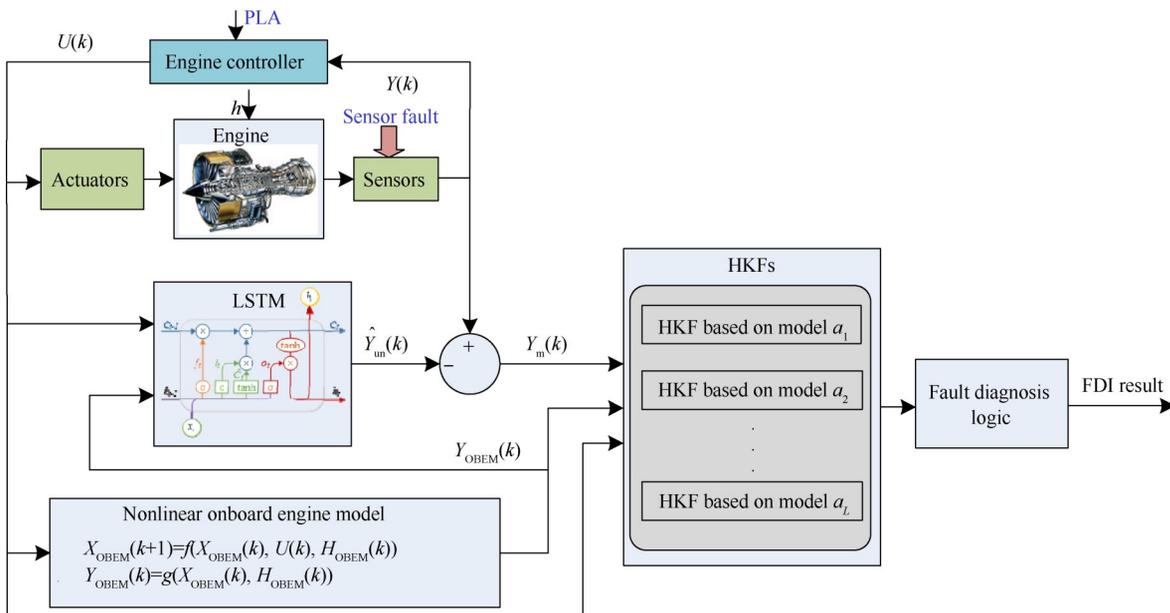


Fig. 1 Hybrid diagnosis architecture of LSTM-HKF based on multiple model

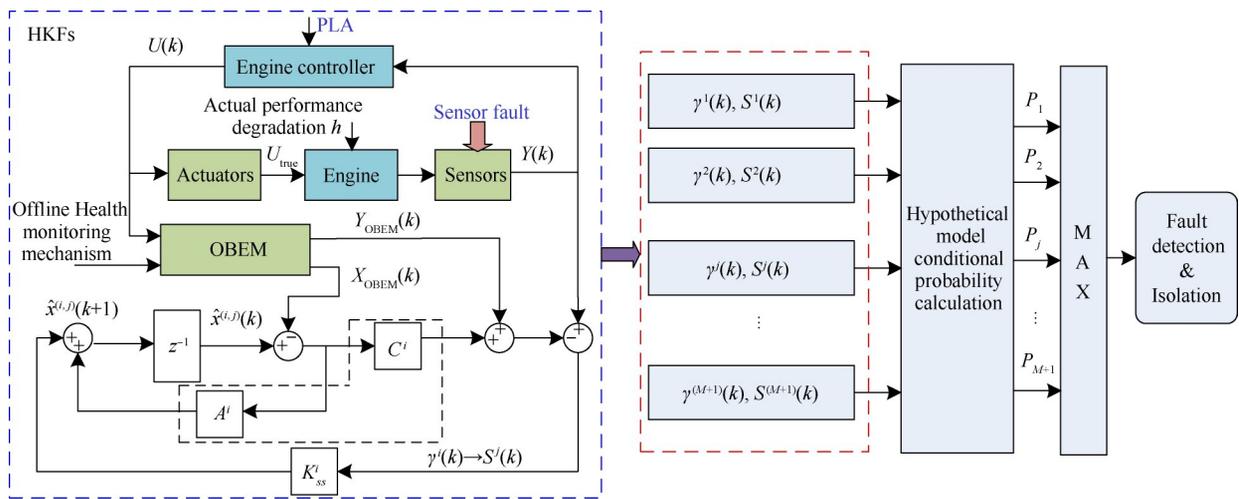


Fig. 2 Structure of fault diagnosis algorithm of hybrid Kalman filters based on multiple model architecture

的假设模型,实现故障的检测与隔离<sup>[16]</sup>。

在基于多模型方法中,假设条件概率 $P_j(k)$ 被定义为 $a$ ,其作为故障参数的概率取决于观测到的测量历史直到第 $k$ 个样本的模式 $a_j$ 的值, $j = 1, \dots, (M + 1)$ , $M$ 为传感器数量。即: $P_j(k) = \Pr [a = a_j | Y(k) = Y_k]$ ,其中 $Y(k)$ 是具有 $Y(1), Y(2), \dots, Y(k)$ 的测量历史随机变量,显示可用的测量直到第 $k$ 个采样时间。同样的, $Y_k$ 是代表了 $Y_1, Y_2, \dots, Y_k$ 测量的历史向量。因此条件概率可以递归计算如式(3)

$$P_j(k) = \frac{f_{y(k)|a, Y(k-1)}(y_j | a_j, Y_{k-1}) P_j(k-1)}{\sum_{j=1}^{M+1} f_{y(k)|a, Y(k-1)}(y_j | a_j, Y_{k-1}) P_j(k-1)} \quad (3)$$

式中 $f_{y(k)|a, Y(k-1)}(y_j | a_j, Y_{k-1})$ 是当前测量的高斯密度函数,由式(4)给出

$$f_{y(k)|a, Y(k-1)}(y_j | a_j, Y_{k-1}) = \frac{1}{(2\pi)^{q/2} \sqrt{|S^{(j)}(k)|}} \times \exp\left[-\frac{1}{2} (\gamma^{(j)}(k))^T (S^{(j)}(k))^{-1} (\gamma^{(j)}(k))\right] \quad (4)$$

式中 $\gamma^{(j)}(k)$ 和 $S^{(j)}(k)$ 表示与故障参数相关联的 $(M+1)$ 个组合模型的残差和残差协方差。如果第 $j$ 个传感器发生故障,则与第 $j$ 个模型相关的概率将大于其他模型的概率,因为其相应的残差矩阵以及协方差矩阵得到的假设模型条件概率最大,概率越大与实际运行的状态越匹配,因此可以基于评估概率并确定其最大值来检测和隔离传感器故障。

### 2.3 LSTM网络训练

长短期记忆网络是一种改进的循环神经网络(Recurrent Neural Network, RNN),相比于一般深度神经网络,LSTM算法在结构上最显著的特征在于其有多个神经元以相似的环结构进行连接,凭借内部储

存及循环结构来处理输入的数据,网络模型中不仅包含网络中隐藏层和隐藏层之间的权重连接,还包括同一隐藏层中神经元内各结构之间的互连<sup>[17]</sup>。LSTM的结构决定了其处理时序数据的优越性,因此,常用于实现时序数据的故障诊断。

由于发动机健康参数的退化和不确定项的存在,LSTM被用来逼近发动机建模的不确定性项,进而提高诊断模型的精度<sup>[18]</sup>。为了训练LSTM网络,可以从无故障的实际航空发动机或整个工作范围的发动机模拟器中收集数据。实际发动机传感器测量值和非线性OBEM输出之间的差异也被用于LSTM训练过程,离线训练过程如图3所示。网络的输入为发动机的输入和OBEM的输出,输出为实际传感器输出与OBEM的偏差。

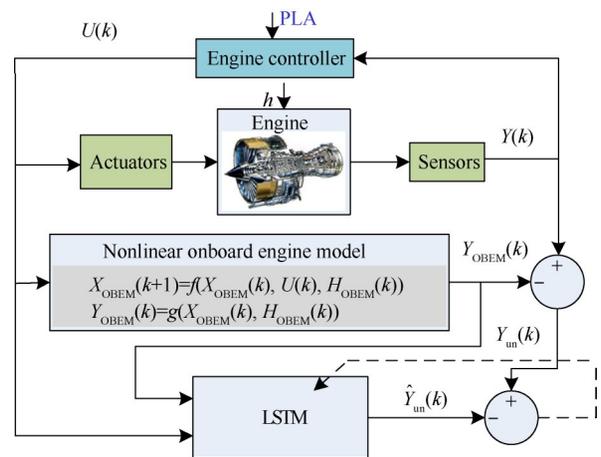


Fig. 3 LSTM network offline training structure

LSTM用于识别 $Y_{un}(k)$ ,是由于不同的不确定性源而产生的输出误差。训练目标是为了最小化均方误差代价函数之和,该函数被定义为 $\frac{1}{2} \sum_{k=1}^r (\hat{Y}_{un}(k) - Y_{un}(k))^2$ ,

其中  $\hat{Y}_{un}(k)$  是提出的 LSTM 生成的估计输出,  $T$  表示训练样本的总长度。

### 3 仿真实验

#### 3.1 航空发动机模型介绍

本文进行仿真实验的研究对象是基于 Gasturb/Matlab 建立的某型民用涡扇发动机部件级非线性动态模型, 其为一台 14 吨级推力的民用涡扇发动机<sup>[19]</sup>, 发动机类型为: 双转子、带增压级、分开排气、大涵道比涡轮风扇发动机, 其结构如图 4 所示。发动机部件级模型是依据气动、热力学定律并按照部件之间的共同工作关系建立的动/静态模型, 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。

MATLAB/Simulink 下民用涡扇发动机模型的输入包括: 飞行环境输入、执行机构输入、健康参数输入。该平台可以模拟民用涡扇发动机常见的传感器故障、执行机构 VSV 故障、部件 HPC 故障、部件 HPT 故障等在线故障。发动机模型测量参数和执行机构参数如表 1 所示, 传感器可能的故障位置有 7 个, 执行机构有 3 个。在其模型的传感器输出上加入高斯白噪声后模拟真实的传感器测量值, 噪声的标准偏差依次设置值为  $[0.25\%, 0.17\%, 0.16\%, 0.5\%, 0.16\%, 0.2\%, 0.5\%]$ , 并对测量值进行归一化处理, 发动机采样周期为  $20\text{ms}$ <sup>[20]</sup>。

#### 3.2 发动机模型不确定性

实际系统受到不同部件(如执行机构、主要部件压气机、涡轮和传感器)不确定性的影响, 参考文献[21], 基于蒙特卡罗方法对发动机非线性部件模型中飞行条件、执行机构、部件健康参数及传感器施加不确定性, 表 2 详细说明了发动机不同部分不确定性的假设值范围。例如, 假设由于各种因素导致的燃油流量误差最大为  $\pm 0.2\%$ , 并且由于各种影响导致的压气机效率可降低  $0.1\%$ 。假设值表示的是实际系统

建模的不确定性, 许多系统的性能即使在健康条件下, 也会随着长期运行而变化, 因此实际系统与标称模型不同。

#### 3.3 航空发动机控制器

典型的航空发动机闭环控制系统结构如图 5 所示, PLA 代表油门杆角度,  $N_{lcmd}$  代表低压转子转速指令,  $W_{lcmd}$  代表燃油流量指令。结构中涵盖了发动机所需的稳态控制、过渡态控制以及极限保护等基本控制单元, 各单元之间采用低高选, 也即 Min/Max 的逻辑选择结构来解决各控制单元之间的逻辑切换问题, 使得在任意时刻只有一个控制器占有主导权限。如采用低选 (Min) 逻辑将稳态控制器与加速控制器以及各个最大限制器连接起来, 使得在任意时刻总是最小的控制指令被输出, 接着又采用高选 (Max) 逻辑将其与减速控制器及各个最小限制器连接起来, 使得在任意时刻总是最大的控制指令被输出, 最后将输出的控制指令作为控制输入直接送给执行机构和发动机。这样, 既保证了控制权限的唯一性, 又保证了燃油指令总是被控制在相对保守的性能之内, 使其既不会超出最大性能限制, 也不会低于最小性能限制<sup>[22]</sup>。

#### 3.4 传感器故障诊断结果仿真

混合架构中主要包含带闭环控制系统和考虑模型不确定性的涡扇发动机模型、机载非线性模型、估计的不确定性的 LSTM 网络、修正的传感器值和基于多模型架构的 HKFs 模块。LSTM 网络训练输入为燃油流量, 输出为机载模型 7 个传感器输出, 输出为不确定性。加入不同的退化类型和大小之后采用 LSTM 网络进行训练, 网络离线训练过程为: 仿真时间  $20\text{s}$  得到所需数据, 每次退化  $0.5\%$ , 总共仿真 20 次, 得到  $90\% \sim 100\%$  之间的数据作为训练数据, 由于加入控制器, 退化过程由燃油流量反应出来。图 6 为加入的退化情况和控制器作用下的燃油流量变化,  $H$  代表健康参数。图 7 是 LSTM 网络估计的不确定性与

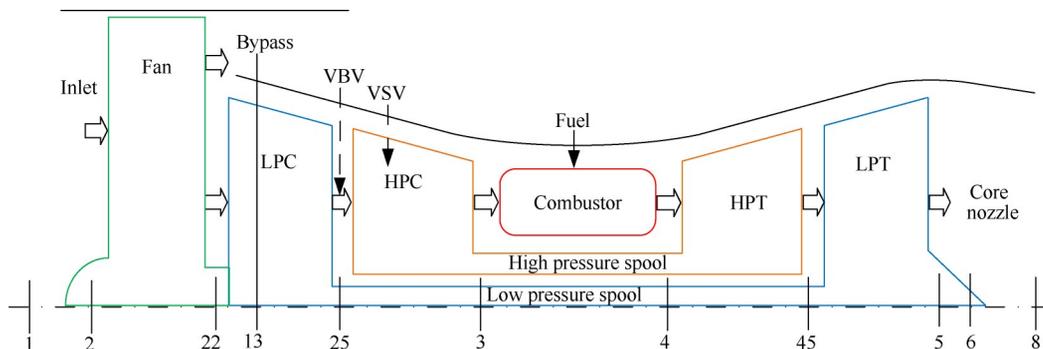


Fig. 4 Civil turbofan engine structure

**Table 1 Engine model measurement parameters and actuator parameters**

Symbol	Description
$e_{FAN}$	Fan efficiency factor
$f_{FAN}$	Fan flow factor
$e_{BST}$	BST efficiency factor
$f_{BST}$	BST flow factor
$e_{HPC}$	HPC efficiency factor
$f_{HPC}$	HPC flow factor
$e_{HPT}$	HPT efficiency factor
$f_{HPT}$	HPT flow factor
$e_{LPT}$	LPT efficiency factor
$f_{LPT}$	LPT flow factor
$N_1$	Fan speed
$N_h$	Core speed
$T_{25}$	Total temperature at LPC outlet
$p_{25}$	Total pressure at LPC outlet
$T_3$	Total temperature at HPC outlet
$p_{s3}$	Static pressure at HPC outlet
$T_{45}$	Total temperature at LPT outlet
$W_f$	Fuel flow
VBV	Variable bleed valve
VSV	Variable stator vane

真实不确定性的对比结果,用  $Y_{un,j}$  代表第  $j$  个传感器的不确定性。限于篇幅,只给出  $N_1$  传感器的不确定性  $Y_{un,1}$  和  $T_3$  传感器的不确定性  $Y_{un,5}$  的实际值与估计值的比较,可以看出,LSTM 网络可以实现对不确定的估计,训练过程中的最大 RMSE 为 0.046。

训练好 LSTM 网络之后,在低压转子转速指令为 4500r/min,高度 11km,  $Ma=0.8$ ,高压涡轮退化 5% 的

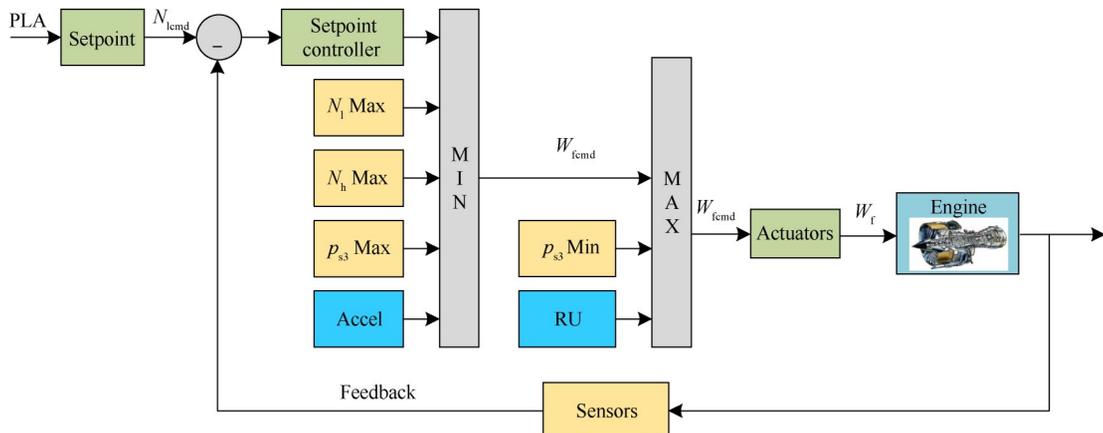
输入条件下进行 100s 仿真,分别进行以下仿真:(1)无故障,加入不确定性;(2)40s 加入 3% 的  $p_{s3}$  传感器偏置故障;(3)40s 加入漂移故障;(4)第 20s 开始加入间歇性故障。四种情况下的传感器输出如图 8 所示,采用混合方法的诊断结果如图 9 所示,其中  $P_1$  为健康模式下的概率, $P_2$  至  $P_8$  依次对应  $N_1, N_h, T_{25}, p_{25}, T_3, p_{s3}$  和  $T_{45}$  共 7 个传感器故障模式下的概率, $p_{s3}$  传感器对应的故障模式概率  $P_7$  在发生故障后变为最大。可以看出本文提出的混合方法可以实现在高压涡轮退化 5% 时的传感器不同类型的故障检测与隔离。

**3.5 不同传感器故障检测与隔离精度对比**

为了对比不同传感器故障诊断与隔离精度,根据文献[16],定义故障诊断时间为隔离时间减去检测时间,检测时间为健康模型概率小于 0.98,隔离时间定义为故障模型概率大于 0.98。在低压转子转速指令为 4500r/min,高度 11km,  $Ma=0.8$  的无退化输入条件下进行 140s 仿真,从  $t=5s$  开始单个传感器下降 3%。故障依次发生且保持 15s,然后传感器恢复正常,5s 后发生下一个传感器故障。图 10 是对 7 个传感器依次植入 3% 的偏置故障之后的诊断结果图,无故障时  $p_1$  健康模式概率最大,传感器发生故障之后与其相对应的故障模式概率变为最大,可以看出采用本文提出的方法可以准确的诊断出传感器故障。图 11 是 7 个传感器故障诊断时间结果图,纵坐标代

**Table 2 Assumptions for uncertainties in different parts of the engine (%)**

Actuators and flight conditions	Uncertainty	Sensors	Uncertainty	Component health parameters	Uncertainty
$W_f$	$\pm 0.2$	$N_1$	$\pm 0.25$	$e_{FAN}f_{FAN}$	-0.1
VBV	$\pm 0.5$	$N_h$	$\pm 0.17$	$e_{BST}f_{BST}$	-0.1
VSV	$\pm 0.5$	$T_{25}$	$\pm 0.16$	$e_{HPC}f_{HPC}$	-0.1
ALT	$\pm 1$	$p_{25}$	$\pm 0.2$	$e_{HPT}$	-0.1
$Ma$	$\pm 2$	$T_3$	$\pm 0.16$	$f_{HPT}$	+0.1
/	/	$p_{s3}$	$\pm 0.2$	$e_{LPT}$	-0.1
/	/	$T_{45}$	$\pm 0.5$	$f_{LPT}$	+0.1



**Fig. 5 Structure of aero-engine closed-loop control system**

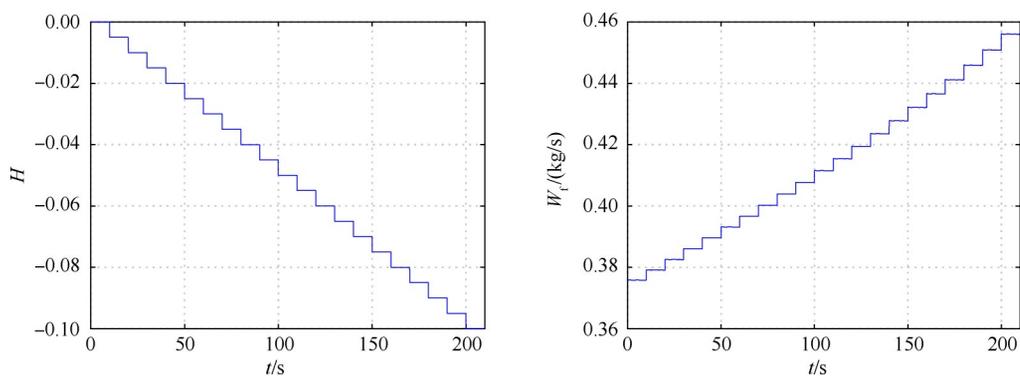


Fig. 6 Added degradation and the change of fuel flow under the action of the controller

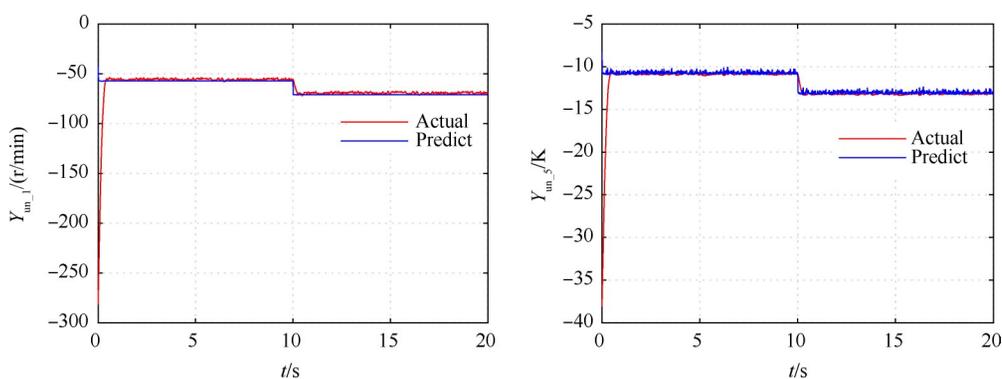


Fig. 7 Comparison of the uncertainty estimated by the LSTM network with the true uncertainty

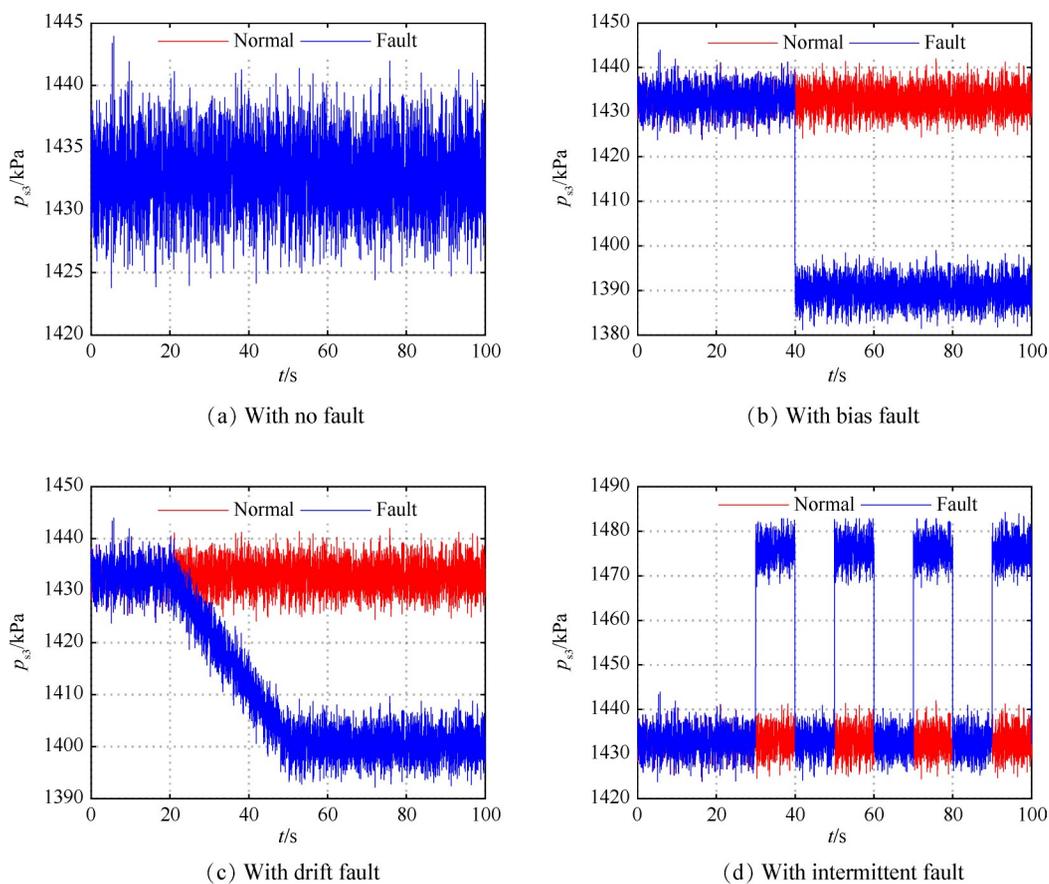


Fig. 8 Sensor output with no fault, bias fault, drift fault, and intermittent fault

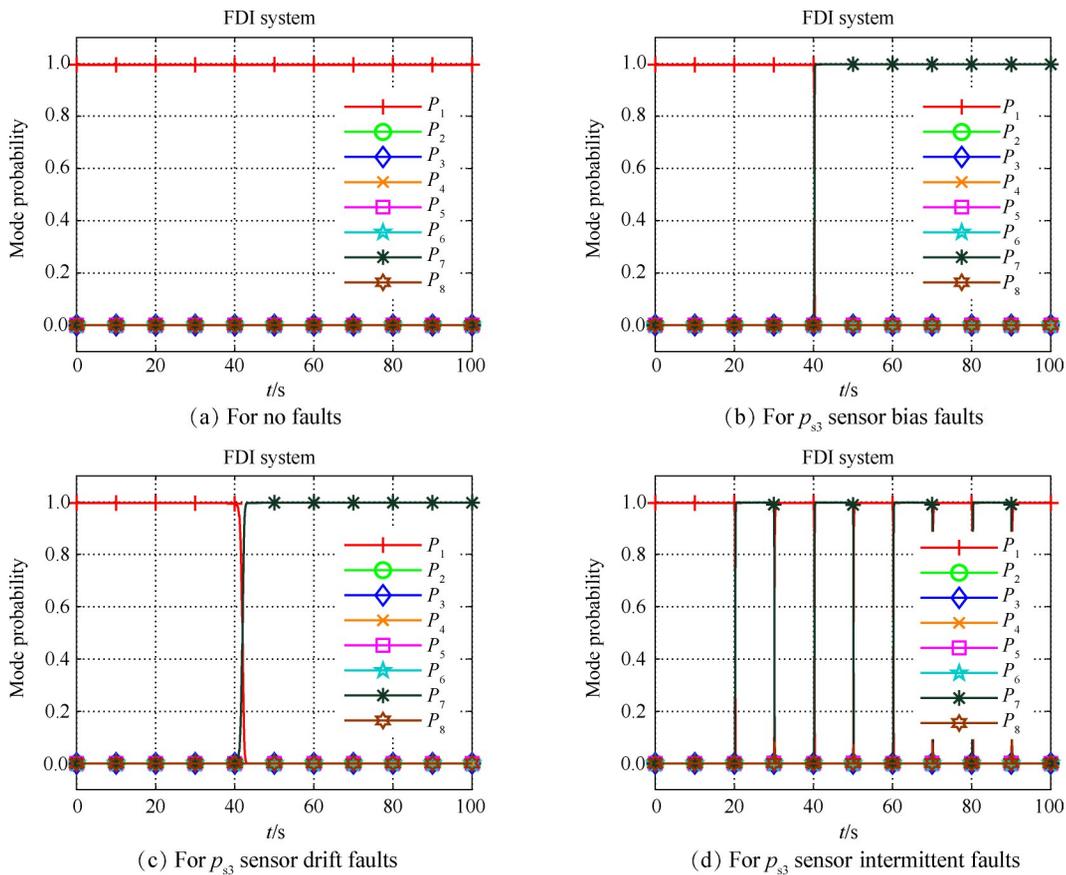


Fig. 9 Diagnostic results for no faults, bias faults, drift faults, and intermittent faults

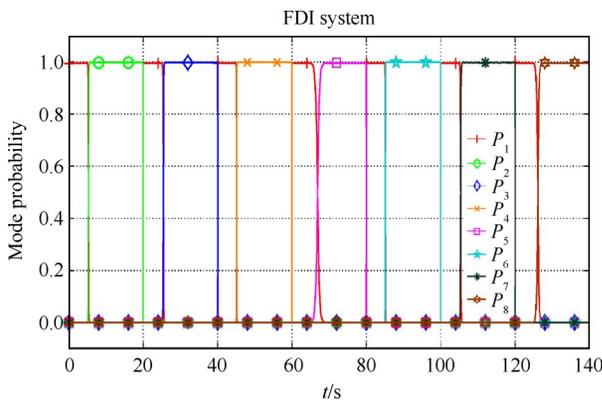


Fig. 10 Diagram of the diagnostic results of 7 sensors implanted in sequence with a 3% bias fault

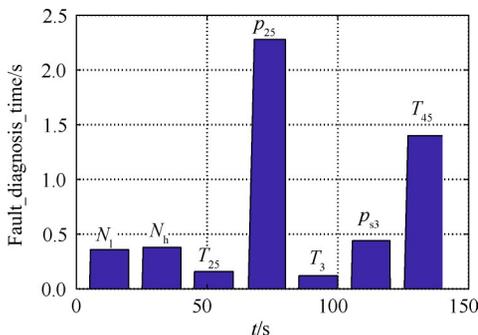


Fig. 11 Histogram of 7 sensors fault diagnosis time results

表故障诊断时间,可以看出  $T_3$  传感器诊断时间最短为 0.12s,  $p_{25}$  传感器诊断时间最长为 2.28s, 不同传感器由于受噪声和诊断模型的影响检测与隔离时间不同, 噪声小的传感器故障诊断时间较短。

### 4 结论

本文通过研究, 得到如下结论:

(1) 提出了基于混合智能故障诊断架构, 利用 LSTM 方法逼近发动机不确定性项, 采用贝叶斯理论计算条件概率克服故障诊断阈值难以选取的问题, 提高了故障诊断结果的置信度。

(2) 建立了带控制器和不确定性的涡扇发动机模型、机载非线性模型和多模型方法的集成架构, 通过 LSTM 网络对不同情况的退化进行离线训练, 实现了混合智能故障诊断模型的建立。

(3) 在加入高压涡轮 5% 的退化之后, 对传感器常见的偏置故障、漂移故障和间歇性故障进行仿真表明, 采用本文提出的方法可以实现更高水平退化下不同故障类型的检测和隔离。

致谢: 感谢国家科技重大专项的资助。

## 参考文献

- [1] Kordestani M, Saif M, Orchard M E, et al. Failure Prognosis and Applications—A Survey of Recent Literature [J]. *IEEE Transactions on Reliability*, 2021, 70(2): 728–748.
- [2] Hanachi H, Mechefske C, Liu J, et al. Performance-Based Gas Turbine Health Monitoring, Diagnostics, and Prognostics: A Survey [J]. *IEEE Transactions on Reliability*, 2018, 67(3): 1340–1363.
- [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] 黄金泉, 王启航, 鲁峰. 航空发动机气路故障诊断研究现状与展望 [J]. *南京航空航天大学学报*, 2020, 52(4): 507–522.
- [5] 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.
- [6] 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).
- [7] 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.
- [8] Yan L, Zhang H, Dong X, et al. Unscented Kalman-Filter-Based Simultaneous Diagnostic Scheme for Gas-Turbine Gas Path and Sensor Faults [J]. *Measurement Science and Technology*, 2021, 32(9): 095905.
- [9] 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.
- [10] 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.
- [11] 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.
- [12] 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.
- [13] 王召广, 杨宇飞, 闫召洪, 等. 基于Relief-LMBP算法的涡轴发动机气路故障模式识别 [J]. *推进技术*, 2021, 42(1): 220–229. (WANG Zhao-guang, YANG Yu-fei, YAN Zhao-hong, et al. Gas Path Fault Mode Identification of Turboshaft Engine Based on Relief-LMBP Algorithm [J]. *Journal of Propulsion Technology*, 2021, 42(1): 220–229.)
- [14] Pourbabaee B, Meskin N, Khorasani K. Robust Sensor Fault Detection and Isolation of Gas Turbine Engines Subjected to Time-Varying Parameter Uncertainties [J]. *Mechanical Systems and Signal Processing*, 2016, 76: 136–156.
- [15] Zhao W, Guo Y, Lai C. Sensor Fault Diagnosis and Estimation Based on Multiple-Model Approach for Aeroengine [C]. *Xiamen: 2018 IEEE CSAA Guidance, Navigation and Control Conference (CGNCC)*, 2018: 1–6.
- [16] 杨庆材. 基于多模型的船用燃气轮机气路故障诊断研究 [D]. 哈尔滨: 哈尔滨工程大学, 2019.
- [17] Yang J, Guo Y, Zhao W. Long Short-Term Memory Neural Network Based Fault Detection and Isolation for Electro-Mechanical Actuators [J]. *Neurocomputing*, 2019, 360: 85–96.
- [18] Yanhua MA, Xian DU, Ximing SUN. Adaptive Modification of Turbofan Engine Nonlinear Model Based on LSTM Neural Networks and Hybrid Optimization Method [J]. *Chinese Journal of Aeronautics*, 2022, 35(9): 314–332.
- [19] 张书刚, 郭迎清, 陆军. 基于GasTurb/MATLAB的航空发动机部件级模型研究 [J]. *航空动力学报*, 2012, 27(12): 2850–2856.
- [20] 孙浩, 郭迎清, 赵万里. 基于GMM聚类方法构建经验模型的机载实时模型改进方法 [J]. *西北工业大学学报*, 2020, 38(3): 507–514.
- [21] Amirkhani S, Chaibakhsh A, Ghaffari A. Nonlinear Robust Fault Diagnosis of Power Plant Gas Turbine Using Monte Carlo-Based Adaptive Threshold Approach [J]. *ISA Transactions*, 2020, 100: 171–184.
- [22] 杨文博, 郭迎清. 涡扇发动机闭环控制系统设计仿真平台 [J]. *航空计算技术*, 2016, 46(3): 90–93.

(编辑:梅 瑛)