

融合模型基残差分析与数据驱动的气路故障诊断方法研究

张 瑞¹, 廖增步², 耿 佳², 宋志平², 王净巍¹

(1. 中国航发沈阳发动机研究所, 沈阳 110066;

2. 西安交通大学 机械工程学院, 西安 710049)

摘要: 为了提高气路故障诊断方法的可靠性, 研究聚焦传感器测量噪声、个体差异和性能衰退等不确定性因素影响, 导致气路故障诊断方法虚警率过高, 无法实现工程应用的问题, 开展了融合模型基残差分析与数据驱动的气路故障诊断方法研究; 为此, 构建了基于发动机模型分析偏差与卷积神经网络建模理论融合的气路故障诊断架构, 在建模过程中充分考虑了传感器测量偏差、个体差异和性能衰退等不确定性因素对气路故障诊断结果的影响, 据此形成了融合模型基残差分析与数据驱动的气路故障诊断方法; 随后, 结合多种飞行轨迹和进气条件开展数值模拟分析验证研究, 对形成的气路故障诊断方法的虚警率进行了定量验证分析; 结果显示, 研究提出的融合模型基残差分析与数据驱动的气路故障诊断方法可在多种不确定性因素存在时, 提供满意的故障诊断精度, 具有工程应用的潜力。

关键词: 涡轮发动机; 气路故障诊断; 虚警率; 不确定性因素; 卷积神经网络

Research on Gas Path Fault Diagnosis Method Based on Model-based Residual Analysis and Data-driven

ZHANG Rui¹, LIAO Zengbu², GENG Jia², SONG Zhiping², WANG Jingwei¹

(1. Shenyang Engine Research Institute of AVIC, Shenyang 110066, China;

2. School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To improve the reliability of gas path fault diagnosis method, the influence of uncertainty factors such as measurement noise, individual difference and performance degradation of focus sensor is studied carefully, which leads to the problem that the false alarm rate of gas path fault diagnosis method is too high to be applied in engineering. The research of gas path fault diagnosis method based on model-based residual analysis and data-driven is carried out in this paper. Therefore, a gas path fault diagnosis framework based on the fusion of engine model analysis deviation and convolution neural network modeling theory is constructed. In the modeling process, the influence of sensor measurement bias individual difference and performance degradation on the gas path fault diagnosis results is fully considered, and the gas path fault diagnosis method combining model-based residual analysis and data-driven is formed. Then, combined with a variety of flight trajectories and air intake conditions, the numerical simulation analysis was carried out to verify the false alarm rate of the gas path fault diagnosis method. The results show that the proposed method can provide satisfactory fault diagnosis accuracy in the presence of a variety of uncertain factors and has the potential of engineering application.

Keywords: turbine engine; gas circuit fault diagnosis; false alarm rate; uncertainty factor; convolution neural network

0 引言

飞机因其在速度方面的明显优势, 被广泛应用于军事、农业、航空货运和航空客运等多个领域^[1-2]。而在过去具有统计数据的几十年里, 全世界已投入了数万亿美元用于飞机的运营和维护。据美国奥纬咨询公司(Oliver Wyman)最近发布的评估报告显示, 2019年全球现役的商用飞机数量为27, 492架。在该保有数量条件下, 商用航空运输的维护、修理和大修(MRO)市场在2019年度的价值约为819

亿美元, 在整个10年的预测期内平均年增长3.5%, 其中约40%用于发动机MRO。依据该增长率到2029年, 这个数字将上升到50%左右^[3]。高昂的发动机维护费用不仅增大了运营商的经济负担, 而由于发动机故障检测和发动机维修造成延误所带来的额外经济损失成为目前亟需重点解决的矛盾之一。造成该矛盾的罪魁祸首是费力且昂贵的计划性维护^[4]。而据现场统计气路部件故障在发生的全部发动机故障中占比虽然不到10%, 但消耗了维修时间的

收稿日期: 2021-06-06; 修回日期: 2021-06-18。

基金项目: 博士后科学基金(2021T140539)。

作者简介: 张 瑞(1978-), 男, 河南南阳人, 大学本科, 高级工程师, 主要从事健康管理方向的研究。

引用格式: 张 瑞, 廖增步, 耿 佳, 等. 融合模型基残差分析与数据驱动的气路故障诊断方法研究[J]. 计算机测量与控制, 2021, 29(7):

30%~50%。在传统基于时间的计划性维护中,大量的时间被浪费在寻找很可能不存在的故障上。但如果通过气路故障诊断方法,则能够实时感知发动机故障,那么维护策略就可以根据发动机自身情况制定,这种在时间上柔性的维修模式被称为视情维护(CBM),避免了计划性维护带来的经济损失。而实现视情维护的一个关键技术便是可靠的气路故障诊断方法。

为了实现可靠的气路诊断,必须了解发动机气路部件的失效机理。一般而言,涡轮发动机的整体性能取决于气路部件的健康状态,其中压气机和涡轮起着很大的作用。在发动机服役期间,在气路部件最有可能出现的问题有两方面,一方面是由于污染^[5],腐蚀^[6]、吸入颗粒物、鸟类撞击引起叶片损伤,造成压缩机效率下降;另一方面是由于叶片烧蚀或蠕变^[7]导致的涡轮机工作能力下降,这些问题最终表现为传感器测量值的变化,即发动机气路部件出现故障时,则会导致发动机运行状态参数相对基线值而言发生变化。基于这一思想,将一系列传感器测量参数与发动机风扇、压气机、高低压涡轮等气路部件故障特征结合起来,以判断发动机的健康状况,实现发动机气路故障诊断。然而,随着基于传感器测量参数的故障诊断方法的深入研究,受传感器噪声和偏差,性能衰退,制造引起的发动机个体差异,建模误差,以及数据集的分散性等不确定性带来的影响,出现了发动机气路故障诊断结果存在可靠性不足,即虚警率过高,无法实现工程应用的问题。

为了解决上述传感器噪声和偏差、性能衰退、制造引起的发动机个体差异等问题导致气路故障诊断方法可靠性不足的问题,广大学者致力于研究涡轮发动机不确定性因素的特征方法。其中,对于传感器噪声和偏差,早在 20 世纪 70 年代,文献 [8] 设计了一种发动机测量噪声表示的标准方法,其中假定传感器噪声服从高斯分布。在性能衰退方面,文献 [9] 根据 JT9D 发动机的历史数据,发表了一份关于气路部件性能衰退的原因和衰退趋势的初步评估报告,研究了各个部件在发动机整体性能衰退中所起的作用。之后,文献 [10] 设计了可模拟性能衰退的分析方法,同时提出了叶片结垢和腐蚀的数学模型。而对于制造导致的个体差异,最近文献 [11] 提出了一个气路部件个体性能差异的划分标准,其可以在少量非设计点计算内推导出来。在初步探索上述问题的基础上,为了提高气路故障诊断方法的可靠性。近年来,研究者们在进行气路故障诊断方法设计和测试时,逐渐考虑了不确定性因素的影响,寻找消除不确定性因素影响的技术手段。其中,为了消除传感器噪声的影响,文献 [12] 将特征提取和模式分类的概念引入至航空发动机的故障诊断方法研究中。文献 [13] 通过鲁棒卡尔曼滤波器设计了一种鲁棒传感器故障检测和隔离(FDI)策略,以容忍制造引起的个体差异和测量噪声。此外,文献 [14] 提出了一种非线性卡尔曼滤波方法,在线

性能衰退的假设下进行测试,在此过程中考虑了包括时间延迟和封隔器脱落的测量不确定性。然而,上述研究成果在进行发动机气路故障诊断方法研究时,分别单独考虑了部分不确定性因素在仿真场景下的设计和验证,但仍缺乏同时考虑多种不同不确定性因素影响的气路故障诊断方法,使得同一方法在实际应用中,由于模拟数据与实际数据的差异,导致可能会呈现出不同的性能分析结果,存在明显虚警。究其原因是不确定性因素考虑不够全面,进而出现发动机气路故障诊断方法可靠性不足,存在虚警率过高的问题。

本文研究针对多种不确定性因素导致气路故障诊断方法可靠性不足的问题,聚焦气路诊断中的不确定性因素描述和表征问题,开展融合模型基残差分析与数据驱动的气路故障诊断方法研究,同时考虑包括传感器噪声和偏差、制造引起的个体差异、性能衰退、建模误差以及数据集分散性等引起的不确定性因素,提出了一种基于卷积神经网络(CNNs)的发动机气路故障诊断方法。并在此基础上,结合数值分析试验,分析形成的气路故障诊断方法的虚警率,进而验证了所提方法的可靠性。据此,本文研究工作阐述主要包括如下 2 部分内容,首先,描述融合模型基残差分析与数据驱动的气路故障诊断方法实现的基本架构及其实现;随后,结合数值模拟仿真方法对形成的发动机气路故障诊断方法开展测试验证研究,量化分析所提方法在多种不确定性因素影响下的虚警率,具体如下文所述。

1 气路故障诊断方法基本架构及其实现

1.1 气路故障诊断方法基本架构

根据算法训练过程中使用信息的类型,现有基于数据驱动的故障诊断方法主要分为两大类,分别为基于模型的方法和基于人工智能的方法^[15]。其中,以 UKF^[16]为代表基于模型的方法依赖于发动机的热力学模型,而基于人工智能的方法如 ANN^[17]和 SVM^[18],通过真实运行数据或模拟数据来学习发动机知识和故障特征,实现发动机气路故障诊断。分析上述两类方法可知,一方面,目前最高效、最流行的诊断方法是基于人工智能的算法^[19],而另一方面,根据文献 [20] 中的对比分析,基于 AI 方法在非高斯噪声、非零传感器偏差和信息缺失的情况下,AI 方法在故障诊断方法中具有较高的可靠性。因此,为了在进行发动机气路故障诊断方法设计时,综合考虑多种不确定性因素影响,提高气路故障诊断可靠性,本文研究引入人工智能的方法作为衡量信息不确定性程度的基准方法。据此结合发动机动态模型提出了融合模型基残差分析与数据驱动的气路故障诊断方法实现架构,具体如图 1 所示。从图中可以看出,本文所提的气路故障诊断方法,主要以形成数据驱动的气路故障诊断方法为主要技术途径,融合了发动机机载模型的分析结果与测量值的残差作为数据驱动模型的输入,进而建立气路故障诊断模型,实现风扇、压气机、高

压涡轮和低压涡轮的气路故障诊断。此处, 以图 2 所示的双转子加力涡扇发动机为例, 具体介绍如何利用图 1 所示的诊断方法架构, 建立气路故障诊断解决方案, 并对提出的不确定性因素表征方案进行测试。对于给定的发动机, 在气路故障诊断方法中一般考虑 4 个气路部件, 包括风扇, 压气机, 高压涡轮和低压涡轮。将发动机个体传感器数据与模型输出的残差、环境参数以及控制器输出的控制量用于故障诊断算法训练过程, 在训练结束时, 将得到一个训练好的卷积神经网络模型。经过简单的微调后, 可以应用于其他发动机个体。借助发动机模型对气路故障诊断问题进行降维, 可以有效降低燃气轮机气路故障诊断的难度。下文将详细阐述融合 CNN 网络实现气路故障诊断算法建立的核心架构。

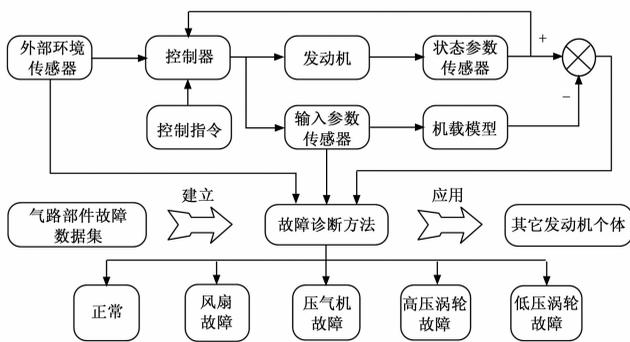


图 1 融合模型基残差分析与数据驱动的气路故障诊断方法实现架构

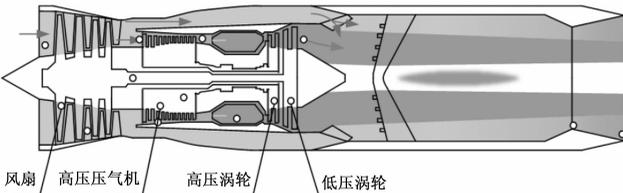


图 2 双转子加力涡扇发动机示意图

1.2 气路故障诊断算法实现的 CNN 架构

基于发动机模型和 CNN 建立气路故障诊断方法实现的总体架构如图 3 所示。如该图所示, 在基于 CNN 网络建立发动机气路故障诊断方法时, 引入了发动机个体差异、传感器误差与噪声和性能衰退等不确定因素, 模拟场景设置遵循真实情况。此外, 本文研究为了基于真实发动机运行特征建立高可靠性气路故障诊断模型, 提高气路故障诊断方法的可靠性, 通过一个或几个发动机个体收集真实数据, 进而实现气路故障诊断模型建立。而在仿真过程中, 所有算法训练和测试数据均由发动机模型代替实际发动机个体, 结合数值分析方法获得, 在此期间考虑了个体差异、性能衰退和部件故障模式等不确定性因素。在这个过程中, 代表发动机机载模型的发动机模型不会有改动。为了阐述建

模过程中考虑的不确定性因素, 随后将依次描述仿真场景细节。

为了使仿真场景更加真实, 在如图 4 (b) 所示的训练用飞行轨迹下, 从 $-15\text{ }^{\circ}\text{C}\sim 30\text{ }^{\circ}\text{C}$ 之间等间隔选取了 4 个海平面温度, 获得了 4 组仿真飞行数据; 在如图 4 (a) 测试用飞行轨迹下, 从 $-15\text{ }^{\circ}\text{C}\sim 30\text{ }^{\circ}\text{C}$ 之间随机选取了 2 个海平面温度, 获取了 2 组仿真飞行数据。这些设定用于表征由于数据集离散性所带来的不确定性因素, 其中高度和温度导致的发动机全包线非相似性起着很大的作用。如图 4 (c) 和 (d) 所示的飞行轨迹, 则用于生成某个刚出厂或已衰退的发动机个体的飞行数据, 用于微调训练后的模型, 具体数据驱动的故障诊断模型训练如下文所述。

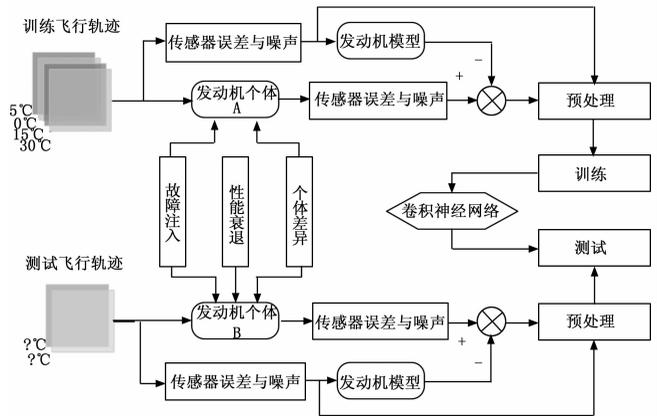


图 3 基于卷积神经网络的发动机气路故障诊断架构方法实现架构

随机选取两台发动机个体进行发动机气路故障模型方法的训练和测试 (发动机 A 用于算法训练, 发动机 B 用于算法测试), 两台发动机的个体差异参数值如图 5 所示, 其中 DEF 为风扇效率偏差、DCF 为风扇流量特性偏差、DEC 为压气机效率偏差、DCC 为压气机流量特性偏差, DPL 为燃烧室总压损失偏差, DEH 为高压涡轮效率偏差, DFH 为高压涡轮最小流道面积偏差, DEL 为低压涡轮效率偏差, DFL 为低压涡轮最小流道面积偏差, DOL 为低压涡轮出口面积偏差, DOE 为外涵道出口面积偏差, DTN 为尾喷管最大喉道面积偏差。在获取数据并进行模型训练过程中, 刚出厂发动机的性能衰退参数均设置为 100%, 而衰退后的发动机的性能衰退表征参数数值与表 1 相同。此外, 通过拉偏相应部件的效率和流量特性参数来模拟部件故障, 其原理及设定值源于文献[18]所示。整个仿真测试环节中考虑了 4 个主要气路部件。

值得注意的是, 由于气路部件不是外场可更换单元, 在大多数情况下, 气路部件在现场具有“不可维修”特征。因此, 对同时发生的多个气路部件故障进行精确的隔离和识别, 对于现阶段气路现场故障诊断意义不大。因为一旦气路部件故障经维修人员确认后, 按照适航规定和维

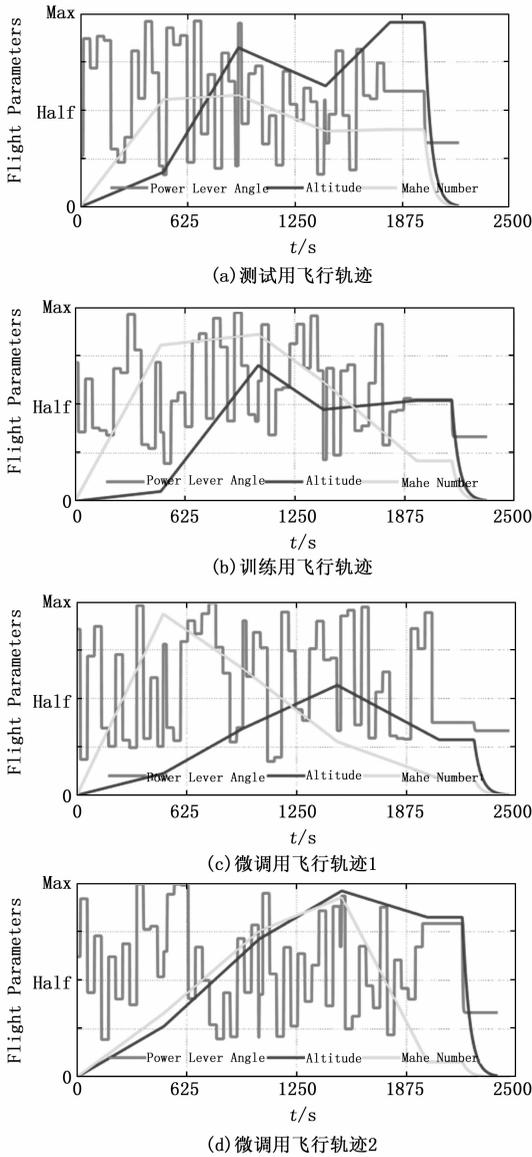


图 4 用于训练和测试环节的发动机飞行轨迹

修指南^[21], 无论是否有其他气路故障, 发动机都必须返厂维修。因此, 更详尽的故障模式分解以及同时发生多个气路故障, 在本文的仿真场景中暂不考虑, 这是符合工程应用需求的。

在上述设定条件下, 将传感器的不确定性因素引入到控制器的输入参数和发动机个体的输出参数中, 获取飞行仿真数据, 同步计算发动机个体输出参数值与机载模型输出之间的偏差。之后, 选取 12 个传感器测量参数作为故障特征参数, 用于预处理, 具体图 6 所示。变量之前的符号 Δ 表示该变量是实际传感器输出和机载模型输出的残差。

选取的故障特征参数应以尽可能少的冗余表征发动机的故障信息。因此, 在 12 个故障特征参数中, 选取了 T_{25}^* 、 P_{25}^* 和 P_0 来表征飞行环境状况, 包括海平面温度、马赫数和高度。同时, T_{25}^* 、 P_{25}^* 用于表征风扇工作状态, T_{31}^* 、 P_{31}

用于表征压气机工作状态。由于没有能承受 2 000 K 高温的传感器, 无法直接测量 T_{41}^* 、 P_{41}^* 等高压涡轮工作参数。因此, 采用了一种以 W_f 、 T_{30}^* 和 P_{30}^* 共同反映高压涡轮和低压涡轮工作状态的换算模型。 n_1 和 n_2 是发动机布莱顿循环的一般表征方法, 分别反映了低压转子和高压转子的性能。此外, 其它传感器测量值如 A_8 、 A_9 和 α_1 , 作为控制的中间变量, 误差相对较大, 它们与已经挑选出的参数 (如 A_8 和 n_1) 耦合在一起, 因此没有被选中。

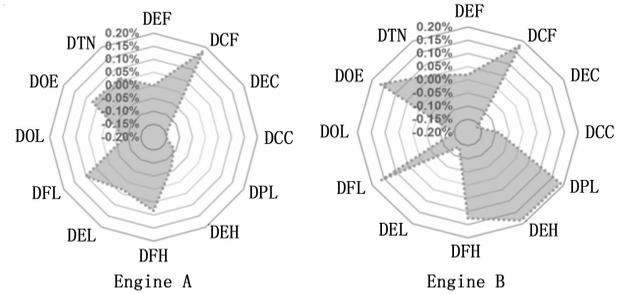


图 5 用于训练和测试环节的发动机个体的个体差异参数值

表 1 性能衰退表征参数 %

表征参数	文献[9]中数值			本文采用
	磨合期	3000 循环数	6000 循环数	
DEF	-0.18	-1.50	-2.85	-0.60
DCF	-0.26	-2.04	-3.65	-0.82
DEC	-0.62	-1.46	-2.61	-0.58
DCC	-1.01	-2.08	-4.00	-0.83
DEH	-0.48	-2.63	-3.81	-1.05
DCH	+0.08	+1.76	+2.57	+0.70
DEL	-0.10	-0.54	-1.08	-0.22
DCL	+0.08	+0.26	+0.42	+0.10

为了提升建立的气路故障诊断模型的鲁棒性, 对数据集集中的每个故障特征参数都经过了标准化处理, 由于残差数据没有明确的边界, 因此通过对每个故障特征参数值除以一个常量值, 使得故障特征参数值被大致限制于 $[-1.0, 1.0]$ 。按照图 6 所示的方式将 10 个采样步长标准化后的故障特征参数值置于一个数据单元中, 作为“伪图像”导入卷积神经网络中进行模型训练和测试。至此, 已经完成了数据样本的生成环节, 最终对于每个类别 (无故障、风扇故障、压气机故障、高压涡轮故障、低压涡轮故障), 生成了 46 916 个训练数据单元和 22 006 个测试数据单元。

表 2 气路部件故障表征参数值 %

故障部件	效率变化	流量变化
风扇	-2.00	-1.10
压气机	-2.00	-0.80
高压涡轮	-2.00	+2.30
低压涡轮	-2.00	+1.60

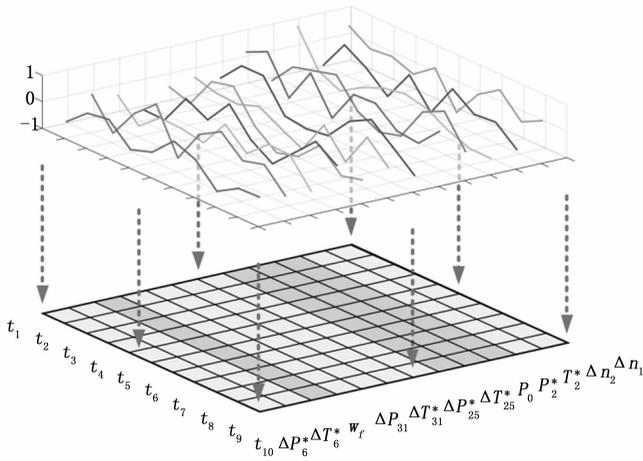


图 6 用于卷积神经网络输入的数据单元

随后, 为了基于上述数据集建立融合模型基残差分析与数据驱动的气路故障诊断方法, 本文设计了一种用于发动机气路故障检测与隔离的卷积神经网络架构, 其结构如图 7 所示。具体地, 采用 3×3 的小型滤波器进行卷积, 每层 16 个通道。在所有的卷积完成后, 插入一个池化层以减少中间数据的空间大小。此外, 为了避免过拟合, 在 Affine 层之后使用了一个 Dropout 层。在优化更新方面, 使用 Adam 优化器^[22]来更新权值。同时, 采用 ReLU 函数作为激活函数, 采用对应的 He 匹配初始化方法^[23], 以避免梯度消失, 获得更好的激活值。结合上述发动机气路故障诊断数据驱动模型建立架构和发动机模型与传感器测量残差数据, 最终形成了融合模型基残差分析与数据驱动的气路故障诊断方法。随后将结合数值模拟分析方法, 对形成的气路故障诊断方法进行分析验证, 结合虚警率的量化评估结果, 分析所提故障诊断方法的可靠性, 为实现工程应用提供初步分析结果。

2 气路故障诊断方法测试验证

气路故障诊断的结果对外场维修具有指导意义。理想情况下, 只在发生警报的情况下才进行常规的外场气路维护, 这样可以节省大量的人力成本, 实现视情维护。如上文所述, 外场目前无法替换非“外场可更换单元”的气路部件。若发现了明显的气路部件故障, 发动机将被返厂进行大修。因此, 重要的是虚警率 (FAR), 其直接表征发动机气路故障诊断方法的可靠性。接下来, 将通过逐渐增加

不确定性因素的数量, 依据量化的虚警率计算方法, 分析融合模型基残差分析与数据驱动的气路故障诊断方法的性能及其变化情况。

首先, 测试了传感器噪声和偏差对发动机气路故障诊断可靠性的影响。以混淆矩阵的形式给出了仅涉及发动机 A 的测试结果。混淆矩阵中的每一列给出了某一气路部件故障的隔离结果, 对角线上是分类正确的样本占比。通过图 4 所示的不同飞行轨迹, 生成相应的运行数据对 CNN 模型进行训练和测试。如图 8 (a) 所示, 当考虑了建模误差和数据集的离散性时, 故障隔离率接近 100%, 只有 0.01% 的风扇故障被误诊为压气机故障, 证明了该方法的有效性。而除了增量漂移以外的其它传感器的噪声和偏差引入后, 故障隔离率开始降低, 出现了漏检 (如图 8 (c) 所示), 而传感器不确定性被替换为相同程度的高斯噪声后, 故障隔离率几乎回到无噪声时的水平 (如图 8 (b) 所示)。由此可见, 更接近实际情况的传感器不确定性的信息量大于常用的高斯噪声。当用含高斯噪声的数据训练的模型用于测试含本文设计的传感器不确定性的数据时, 如图 8 (d) 所示, “真正的”故障隔离率与图 8 中的“模拟”故障隔离率 (b) 相比大幅下降, 这证明了基于高斯噪声假设开发的气路故障诊断方法在实际应用过程中很可能表现不佳。这也是本文所提出的传感器不确定性的优势所在。另外, 从图 8 (c) 可以看出, 风扇的故障特征最不明显, 同一转子上各气路部件的故障表现相似, 这符合发动机的机理。

随后, 将含传感器不确定性数据训练的模型直接用于测试发动机 B 的飞行数据, 测试结果如图 9 (a) 所示。虽然 CNN 模型泛化能力较强, 但也会出现虚警, 虚警率粗略计算为 0.33%。虽然数值很小, 但由于气路部件故障发生概率极低, 这个程度的虚警率仍然是难以接受的。假设气路故障发生率为 1% (这远远高于实际情况), 在气路故障诊断系统报警的时候, 虚警率将高达 25%。在某种程度上这将成为维护的难题。

为了解决这一问题, 使用发动机 B 的无故障数据对训练后的模型进行微调, 即在如图 4 (c) 所示的微调用飞行轨迹 1 下, 收集飞行数据对上一步已经训练后的模型进行微调, 用于微调的数据包含海平面温度在 $-15\text{ }^{\circ}\text{C} \sim 30\text{ }^{\circ}\text{C}$ 之间 4 个等间隔选取温度下的数据。微调后, 虚警率回到 0。然而, 风扇故障漏检率增加了, 如图 9 (b) 所示。这个现象是可以解释的, 即仅使用一个标签 (无故障) 的数据对

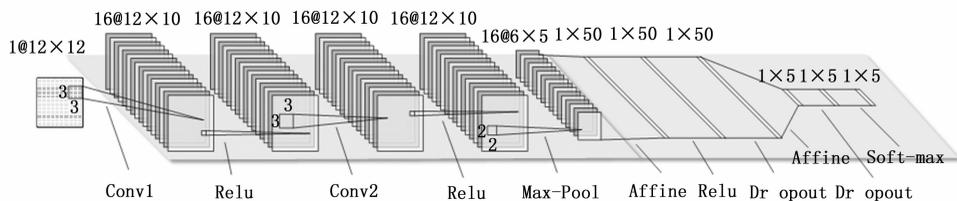


图 7 用于发动机气路故障诊断的卷积神经网络架构

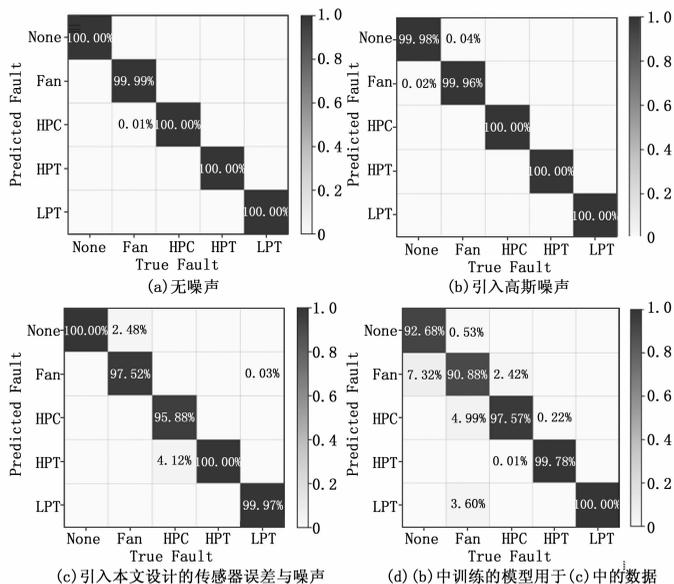


图 8 发动机 A 训练的模型，测试发动机 A 测试数据

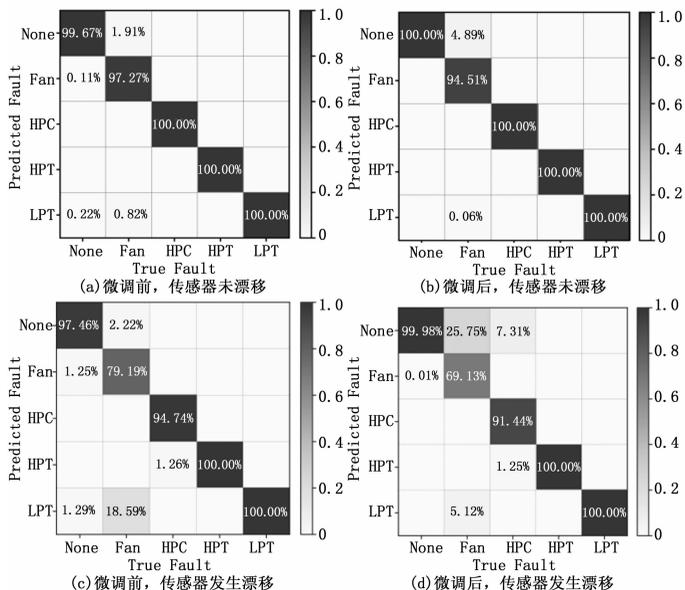


图 9 发动机 A 训练的模型，测试发动机 B

CNN 模型进行微调，扩大了这一类别的边界，而风扇故障又最接近于无故障，因此部分靠近边界的风扇故障被误诊为无故障，即发生漏检。此外，尽管故障漏检率有所增长，但由于气路部件故障发生概率极低，这种程度的漏检率仍在可接受的范围内。

如果发动机 B 不是全新的，而是大修过的，由于传感器在发动机生命周期内的不同时刻更换过，气路上的传感器可能会出现不同程度的增量漂移。如图 9 (c) 显示了增量漂移对气路故障检测与隔离的影响。与 (a) 相比，各个原先隔离错误的情况所占比例均有所增加 (图中表现为同位置格子的数值增加)，其中新增的隔离错误情况只有一

项，占压气机故障的 1.26%。同样地，使用如图 4 (c) 所示的微调用飞行轨迹 1，生成的包含所有传感器不确定性因素的无故障数据，来微调如图 9 (c) 中采用的模型，调整后模型的测试结果如图 9 (d) 所示。然而，微调后的结果并不如图 9 (b) 中的更优。从信息量的角度来考虑该问题，在如图 9 (a) 中发生的虚警源自于缺乏发动机个体信息，在本文中表示为制造引起的个体差异，通过学习发动机个体 B 在另一条飞行轨迹下的无故障数据可以进行补偿。由此得出结论：制造过程引发的发动机个体间的性能差异会影响无故障状态的边界，可以利用目标发动机个体的信息来微调无故障状态的边界。

第三个测试基于衰退后的发动机 B 开展，该发动机即将返厂大修。发动机 B 的性能衰退程度如表 1 的最后一列所示，其气路各类传感器由于多次更换而产生了不同程度的漂移。图 10 (a) 显示了如图 9 (d) 中微调后的 CNN 模型直接用于衰退后发动机 B 的测试结果。性能衰退对发动机气路故障表现的影响远超个体差异，甚至比风扇故障的特征还要明显，这也可以从性能衰退的参数数值上大致反映出来。随后，模型又通过在图 4 (d) 所示的微调用飞行轨迹 2 下生成的数据进行了二次微调，二次微调后故障诊断方法的测试结果如图 10 (b) 所示，对比微调前，虚警率显著降低。

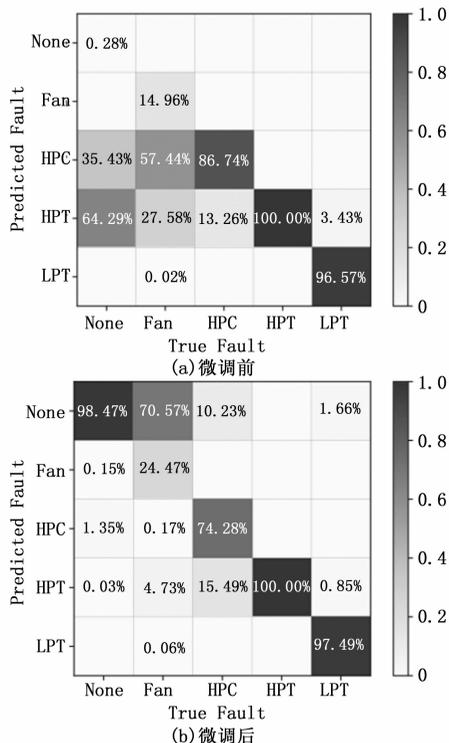


图 10 大修后的发动机 B 微调的模型，测试衰退后的发动机 B

3 结束语

本文开展了融合模型残差分析与数据驱动的气路故

障诊断方法研究, 该方法可同时考虑传感器噪声和偏差、建模误差、制造引起的发动机个体差异、性能衰退和数据集离散性等多种不确定性因素的影响, 实现高置信度气路故障诊断, 为实现基于状态的发动机维修 (CBM) 提供技术基础。并以某双轴加力涡扇发动机为例, 分析了不确定性对气路故障诊断结果的影响。通过系统的比较和分析可以看出, 不同的不确定性因素对气路故障诊断有不同的影响特征, 其中高斯白噪声等高频不确定性因素可以通过学习足量的数据来消除; 个体差异等固定不变的不确定性因素带来的影响可以通过微调来消减, 通过数值分析试验可以看出, 本文研究提出的融合模型基残差分析与数据驱动的气路故障诊断方法可在多种不确定性因素存在时, 提供满意的故障诊断精度, 具有满意的工程应用潜力。

参考文献:

- [1] KUMAR U D. New trends in aircraft reliability and maintenance measures [J]. *Journal of Quality in Maintenance Engineering*, 1999, 5 (4): 287 - 295.
- [2] KUMAR U D. Setting reliability goals for future air systems [J]. *IETE Technical Review*, 2001, 18 (1): 5 - 9.
- [3] WYMAN O. Global Fleet MRO Market Forecast Commentary 2019-2029 [R]. Oliver Wyman, 2019.
- [4] 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.
- [5] MEHER-HOMJI C B, CHAKER M, BROMLEY A F. The Fouling of Axial Flow Compressors; Causes, Effects, Susceptibility, and Sensitivity [C] // *ASME Turbo Expo: Power for Land, Sea, & Air*, Orlando, Florida, USA, 2009.
- [6] GANNAN A. Cascade testing and CFD applied to gas turbine performance improvement with compressor cleaning [D]. Cranfield University, 2010.
- [7] EJAZ N, QURESHI I N, RIZVI S A. Creep failure of low pressure turbine blade of an aircraft engine [J]. *Engineering Failure Analysis*, 2011, 18 (6): 1407 - 1414.
- [8] ABERNETHY R, THOMPSON J J. Uncertainty in gas turbine measurements [C] // *AIAA/SAE 9th Propulsion Conference*, Las Vegas, 1973.
- [9] SALLEE G P. Performance deterioration based on existing (historical) data; JT9D jet engine diagnostics program [J]. *Journal of Research in Chemical*, 2016, 3 (2): 264 - 269.
- [10] LAKSHMINARASIMHA A N, BOYCE M P, MEHER-HOMJI C B. Modeling and Analysis of Gas Turbine Performance Deterioration. *ASME* [J]. *Journal of Engineering for Gas Turbine and Power*, 1994, 116 (1): 46 - 52.
- [11] CHEN M, ZHANG J, TANG H. Interval analysis of the standard of adaptive cycle engine component performance deviation [J]. *Aerospace Science and Technology*, 2018, 81: 179 - 191.
- [12] SARKAR S, JIN X, RAY A. Data-driven fault detection in aircraft engines with noisy sensor measurements [J]. *Journal of Engineering for Gas Turbines and Power*, 2011, 133 (8), 081602.1 - 081602.10.
- [13] POURBABAE 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.
- [14] LU F, GAO T, HUANG J, et al. Nonlinear Kalman filters for aircraft engine gas path health estimation with measurement uncertainty [J]. *Aerospace Science and Technology*, 2018, 76: 126 - 140.
- [15] FENTAYE A D, BAHETA A T, GILANI S I, et al. A Review on Gas Turbine Gas-Path Diagnostics: State-of-the-Art Methods, Challenges and Opportunities [J]. *Aerospace*, 2019, 6 (83): 1 - 53.
- [16] DEWALLEF P, LE ONARD O. On-line performance monitoring and engine diagnostic using robust Kalman filtering techniques [C] // *ASME Turbo Expo 2003*, collocated with the 2003 International Joint Power Generation Conference, Atlanta, Georgia, USA, 2003.
- [17] OGAJI S, LI Y G, SAMPATH S, et al. Gas path fault diagnosis of a turbofan engine from transient data using artificial neural networks [C] // *International Joint Power Generation Conference*, Atlanta, Georgia, USA, 2003.
- [18] XI P, ZHAO Y, WANG P, et al. Least squares support vector machine for class imbalance learning and their applications to fault detection of aircraft engine [J]. *Aerospace Science and Technology*, 2019, 84: 56 - 74.
- [19] ROMESIS C, ARETAKIS N, ROUMELIOTIS I, et al. Experience With Condition Based Maintenance Related Methods and Tools For Gas Turbines [C] // *7th International Gas Turbine Conference*, Brussels, Belgium, 2014.
- [20] VOLPONI A J, DEPOLD H, GANGULI R, et al. The use of Kalman filter and neural network methodologies in gas turbine performance diagnostics: a comparative study [J]. *Journal of Engineering for Gas Turbines and Power*, 2003, 125 (4): 917 - 924.
- [21] ADMINISTRATION F A. *Aviation Maintenance Technician Handbook - Powerplant*: FAA [M]. Aviation Supplies & Academics, 2012.
- [22] KINGMA D P, BA J. Adam: A method for stochastic optimization [J]. *Computer Science*, 2014: 1412.
- [23] HE K, ZHANG X, REN S, et al. Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification [C] // *2015 IEEE International Conference on Computer Vision (ICCV)*, Santiago, Chile, 2015.