

DOI: 10.13382/j.jemi.2017.09.002

基于相关时间规整的航空发动机缓变故障诊断^{*}

周媛¹ 左洪福² 刘鹏鹏³

(1. 南京信息工程大学电子与信息工程学院 南京 210044; 2. 南京航空航天大学民航学院 南京 210016;
 3. 中国船舶工业系统工程研究院 北京 100094)

摘要:针对航空发动机退化导致的缓变故障诊断问题,提出了一种基于相关时间规整算法的诊断模型,该模型通过挖掘发动机退化过程中过渡信息,根据退化数据中发动机状态变化特征来识别故障模式。通过仿真数据和实际案例数据实验证明,在监测数据满足1~2个飞行循环间隔前提下,该模型能够区分发动机正常状态和故障状态,对发动机本体的缓变故障能够定位到部件级,平均 G -mean值为0.9487,拥有较好的鲁棒性和准确度,为民航发动机健康管理提供了一种可行的工程方法。

关键词:航空发动机;缓变故障;故障诊断;相关时间规整;并发故障

中图分类号: TN606; V239 文献标识码: A 国家标准学科分类代码: 520.2040

Aero-engine gradual changing fault diagnosis based on canonical time warping algorithm

Zhou Yuan¹ Zuo Hongfu² Liu Pengpeng³

(1. College of Electronic and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China; 2. College of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;
 3. Systems Engineering Research Institute, China State Shipbuilding Corporation, Beijing 100094, China)

Abstract: Aiming at the degradation-caused gradual changing fault diagnosis of aero-engine, this paper proposed a diagnosis model based on the canonical time warping (CTW) algorithm, which can discriminate the fault pattern based on the transition features from degradation data via mining the transition information of degradation. We conducted the proposed model on both simulated data and real data. The experimental results show that the proposed model can recognize the normal state and fault state and locate the gradual changing fault in component level, whose G -mean value is 0.9487 in the premise that the flight cycle interval is 1 or 2. The proposed model provides a feasible engineering method for civil aviation aero-engine health management, and has good robustness and high accuracy.

Keywords: aero-engine; gradual changing fault; fault diagnosis; the canonical time warping algorithm; concurrent fault

0 引言

航空发动机使用就会产生正常的性能退化,性能退化到一定程度出现的故障就是缓变故障;正常性能退化阶段可通过水洗等措施来延长发动机的使用时间,而缓变故障则需要进行识别、定位,这样才能有效保证飞行安

全。故障诊断一直是健康管理领域的研究重点,随着机器学习的兴起,数据驱动的故障诊断受到越来越多国内外学者的关注,纵观近5年各领域故障诊断的相关研究^[1-8],数据驱动的故障诊断方法可分为信号处理法、统计分析法以及人工智能法。信号处理法本质是利用信号在时域、频域上的特征进行故障诊断^[9-11],这类方法直接对在线输出信号进行分析,不需要对动态系统建模,而是

基于人们对系统的先验知识建立起故障模式,实现起来简单,但是面对复杂系统的故障诊断,往往需要结合统计分析法或人工智能法对大量历史数据进行分析以提高故障诊断性能^[12]。统计分析法通过求解假定的概率分布模型或随机过程来拟合发动机实际退化适用于小样本而无法处理大数据,人工智能法近几年常用极限学习机^[13-14]、支持向量机^[15]、神经网络^[16]、相似性聚类^[17]等,需要学习故障特征并进行识别。航空发动机作为一个安全性要求极高的复杂设备,其故障数据量远少于非故障数据量,常用的统计分析法和人工智能法面对这种数据分布不均衡的实际情况,对多类(非故障)的识别精度提高,而对少类(故障)的识别精度更低,甚至无法识别^[18-19]。

采用时间序列样本相似性对比进行缓变故障诊断可以避免样本数据分布不均衡的影响,目前有基于动态时间规整(dynamic time warp, DTW)的故障诊断研究^[20-24]见诸报道,但DTW算法是直接通过监测数据和样本在时间轴上对齐以达到识别目的,当发动机监测参数增多以及噪声干扰会使得DTW算法效率、性能下降。因此本文提出了基于相关时间规整(canonical time warping, CTW)的发动机缓变故障诊断模型,将经维修确认过的发动机历史监测数据作为样本(包含非故障、故障样本),无需用样本训练模型,而是挖掘发动机演化过程中的过渡信息,通过在翼发动机监测数据序列和样本在特征空间进行相似性对比以确定发动机的模式,从而实现对航空发动机缓变故障的诊断;经仿真数据和真实数据实验对比分析可知该模型对有噪声干扰的监测数据进行缓变故障诊断拥有较好的鲁棒性和准确度。

1 基于相关时间规整的发动机缓变故障诊断

1.1 相关时间规整算法

由于动态时间规整方法要求两个时间序列的维度一致,典型相关分析(canonical correlation analysis, CCA)^[25]算法要求两个时间序列的样本个数一致,因此,Zhou等人^[26]将典型相关分析引入动态时间规整提出了CTW算法,该算法将长度不同的两个时间序列进行特征提取的同时在特征空间进行相似度分析,可以解决时空不一致的时间序列相似度匹配问题。

假设有两个时间序列 $X = [x_1, \dots, x_{n_x}] \in \mathbb{R}^{d \times n_x}$ 和 $Y = [y_1, \dots, y_{n_y}] \in \mathbb{R}^{d \times n_y}$, $V_x \in \mathbb{R}^{d \times d}$ 和 $V_y \in \mathbb{R}^{d \times d}$ 分别是 X 和 Y 的到低维特征空间的映射, W_x 、 W_y 分别是 X 和 Y 的规整矩阵。

最小化CTW的目标函数如式(1)。

$$\min_{V_x, V_y, W_x, W_y} J_{CTW} = \|V_x^T X W_x - V_y^T Y W_y\|_2^2 + \phi(V_x) + \phi(V_y) \quad (1)$$

其中,正则化函数 $\phi(\cdot)$ 的定义同式(2)。

$$\phi(V) = \frac{\lambda}{1-\lambda} \|V\|_2^2 \quad (2)$$

V_x 和 V_y 要满足如式(3)正交约束。

$$\Phi = \{\{V_x, V_y\} \mid V_x^T ((1-\lambda)X W_x W_x^T X^T + \lambda I) V_x = I, \\ V_y^T ((1-\lambda)Y W_y W_y^T Y^T + \lambda I) V_y = I\} \quad (3)$$

定义矩阵 A 、 B 如式(4)和(5)。

$$A = \begin{bmatrix} 0 & X W_x W_y^T Y^T \\ Y W_y W_x^T X^T & 0 \end{bmatrix} \quad (4)$$

$$B = (1-\lambda) \begin{bmatrix} X W_x W_x^T X^T & 0 \\ 0 & Y W_y W_y^T Y^T \end{bmatrix} + \lambda I \quad (5)$$

对 A 、 B 进行特征分解,得到前 d 个特征向量即为 V_x 和 V_y ;通过不断迭代交替计算时间序列的低维特征 V 和规整矩阵 W ,当目标函数 J_{CTW} 的变化量小于设定阈值时,此时 V_x 、 V_y 和 W_x 、 W_y 即为最终低维特征和规整矩阵。通过规整矩阵 W ,可以反算得到规整路径,实现两个时间序列在特征空间的对齐。

1.2 发动机缓变故障诊断模型

针对用高维时间序列表征的发动机缓变故障,用CTW方法进行特征选择并将数据统一投影到特征空间,在减少噪声和异常数据干扰的同时,能够将不同退化速度的数据处理到同一时间尺度上进行相似性比较,充分考虑了发动机的演化个性,诊断模型如图1所示。

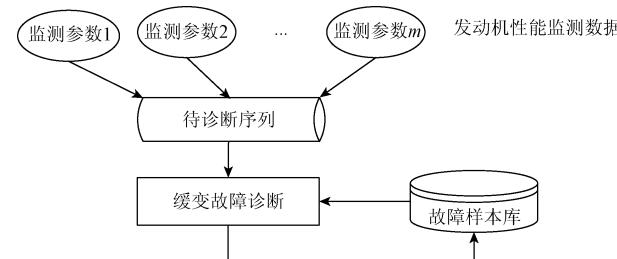


图1 航空发动机缓变故障诊断模型

Fig. 1 Gradual changing fault diagnosis model of aero-engine

将待诊断发动机从安装到下发对应所有飞行循环的各监测参数组成一个时间序列 $X = [x_1, \dots, x_{n_x}] \in \mathbb{R}^{d \times n_x}$, 样本库中共有 N 个缓变故障样本,其中某一缓变故障样本表示为 $Y = [y_1, \dots, y_{n_y}] \in \mathbb{R}^{d \times n_y}$,具体识别流程如图2所示。

首先,输入待识别序列 X ,依次从样本库中取出样本 Y ,对 X 和 Y 进行规范化;然后对规范化后的序列利用CTW算法求取相应的低维特征空间映射 V_x 、 V_y 以及特征空间的规整矩阵 W_x 、 W_y ;最后按式求出待识别序列

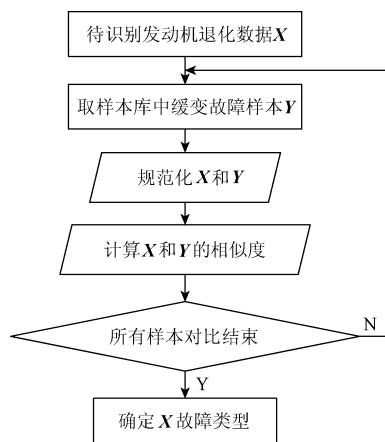


图2 航空发动机缓变故障诊断流程

Fig. 2 Flow chart of gradual changing fault diagnosis for aero-engine

和各样的规整距离,根据式可确定 X 是第 I 类缓变故障,至此故障诊断结束。

$$dist_j = \|V_x^T \hat{X} W_x - V_y^T \hat{Y} W_y\|^2 \quad (6)$$

$$I = \operatorname{argmin}_j \{dist_1, \dots, dist_N\} \quad (7)$$

式中: $j = 1, \dots, N$ 。

因为表征发动机状态的参数很多,此处采用式(8)、(9)对数据进行规范化以消去不同参数量纲的影响,得到规范化后的 \hat{X} 和 \hat{Y} 。

$$\tilde{x}_{ik} = x_{ik} - \bar{x}_k \quad (8)$$

式中: $\bar{x}_k = (x_{1k} + \dots + x_{nk})/n_x$, $i = 1, \dots, n_x$, $k = 1, \dots, d_x$ 。

$$\tilde{y}_{ik} = y_{ik} - \bar{y}_k \quad (9)$$

式中: $\bar{y}_k = (y_{1k} + \dots + y_{nk})/n_y$, $i = 1, \dots, n_y$, $k = 1, \dots, d_y$ 。

计算 \hat{X} 和 \hat{Y} 的对齐矩阵 W_x 、 W_y 以及相应的特征映射 V_x 、 V_y 的具体步骤如下。

1) 设定循环变量 $l = 1$, 最大循环次数 20, 循环终止阈值 $th = 0.01$, 参数 $\lambda = 0$, 初始 $d = \min(d_x, d_y)$, $V_x^{(0)} = I_d \in R^{d \times n_x}$, $V_y^{(0)} = I_d \in R^{d \times n_y}$;

2) 对 $V_x^T \hat{X}$ 和 $V_y^T \hat{Y}$ 计算得到 $W_x^{(l)}$ 和 $W_y^{(l)}$;

3) 对 $\hat{X} W_x^{(l)}$ 和 $\hat{Y} W_y^{(l)}$ 进行特征分解, 求得 $V_x^{(l)}$ 和 $V_y^{(l)}$;

4) 计算目标函数 $J_{CTW}^{(l)}$, 若 $|J_{CTW}^{(l)} - J_{CTW}^{(l-1)}| \leq th$, 则结束循环; 否则, $l = l + 1$ 并跳到步骤 2)。

一旦缓变故障类型被确认, 该发动机退化序列又作为有标签的样本被放回样本库中。

2 发动机缓变故障诊断实验及分析

针对实际工程中各类缓变故障数据量不可知的情况(可能有的故障是多发故障而有的故障很少发生), 如果单纯用正确诊断个数除以样本总数来评价诊断模型性能是不合适的, 所以采用 G -mean^[27] 指标来评价诊断效果, 该指标综合了各类数据的分类结果, 是一种衡量整体分类性能的评价指标, 它越高表明模型对各退化模式的识别性能越好。

2.1 仿真数据实验

采用雅典国家技术大学的仿真软件 LTT(laboratory of thermal turbo machine) 仿真了两种工况下发动机本体缓变故障, 工况 1 下故障包括风扇叶片污垢(F1)、风扇叶间隙(F2)、高压压气机叶间隙(F3)、高压涡轮叶片腐蚀(F4)、高压涡轮污垢(F5)、高压涡轮叶间隙(F6)、低压涡轮污垢(F7)、和低压涡轮叶间隙(F8); 工况 2 下故障包括风扇叶间隙故障(F9)、高压涡轮叶间隙故障(F10)、高压压气机叶间隙和高压涡轮叶间隙并发故障(F11)以及和风扇叶间隙和高压涡轮叶间隙并发故障(F12)。

LTT 数据采用 8 个监测参数, 分别是低压转自转速(NL)、高压转子转速(NH)、风扇出口压力($P13$)、风扇出口温度($T13$)、高压压气机出口压力($P3$)、高压压气机出口温度($T3$)、尾气排气温度($T6$)和燃油流量(Wf), 为了模拟真实情况我们对各性能参数按照表 1 添加了高斯观测噪声。按照不同退化速度从原始监测数据中生成了 60 个序列, 此处随机对每类故障各取 50 个作为故障样本, 剩下的 10 个作为待识别序列。

表1 典型涡扇发动机气路参数测量噪声

Table 1 Measurement noise of typical turbofan engine gas path

参数	$NL/(r \cdot min^{-1})$	$NH/(r \cdot min^{-1})$	$P13/Pa$	$T13/K$	$P3/KPa$	$T3/K$	$T6/K$
3σ	6	12	300	2	5	2	2

1) 单部件缓变故障识别

LTT1 数据集包含了工况 1 下的 8 种发动机本体故障对应的退化数据, 此处以高压涡轮叶片腐蚀(F4)和高压涡轮叶间隙(F6)故障数据为例, 选取两种故障下各 4 台发动机的 NH 和 $T6$ 参数变化过程如图 3、4 所示, 不同故障在某些监测参数上有类似的趋势(NH 下降), 从数据上无法直接看出差异。

分别将本文模型和 DTW 算法对 LTT1 数据集的 8 类故障进行识别。本文模型识别过程中保留原始数据 95% 的能量, 原始数据被映射到一个 7 维特征空间, 以

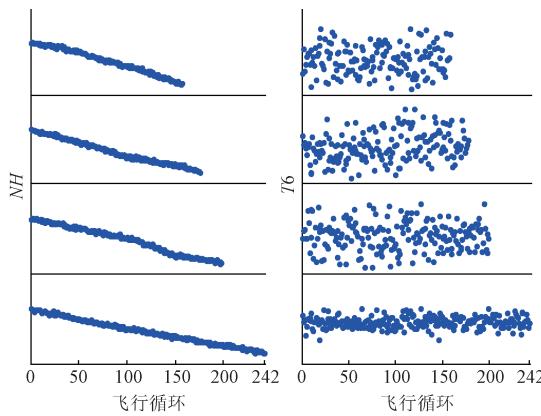


图 3 F4 高压涡轮叶片腐蚀

Fig. 3 F4 high pressure turbine fan erosion

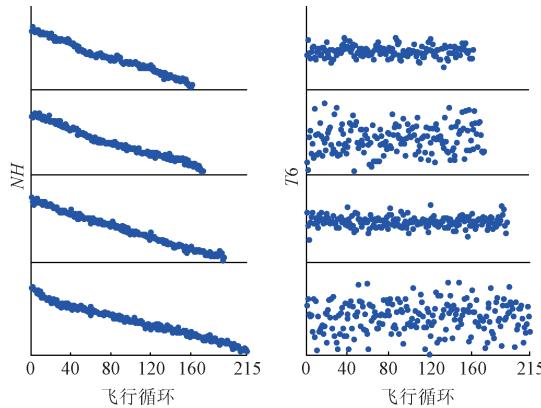


图 4 F6 高压涡轮叶间隙

Fig. 4 F6 high pressure turbine fan tip

F1 类数据为例,本文模型得到的 F1 类缓变故障和故障样本的最小规整距离如表 2 所示(保留两位小数,最小距离加粗)。

表 2 F1 类缓变故障数据和样本最小规整距离(本文模型)

Table 2 Minimum warp distance between F1 gradual changing fault data and samples (the proposed model)

样本	待诊断序列编号									
	1	2	3	4	5	6	7	8	9	10
F1	0.32	0.35	0.28	0.31	0.33	0.36	0.33	0.34	0.37	0.35
F2	0.81	0.79	0.80	0.79	0.81	0.70	0.81	0.73	0.78	0.75
F3	1.06	0.61	0.52	0.80	0.77	0.80	0.98	0.94	1.18	1.06
F4	0.33	0.37	0.35	0.37	0.47	0.41	0.32	0.35	0.66	0.46
F5	0.53	0.52	0.55	0.86	0.78	0.76	0.85	0.79	0.95	0.87
F6	0.71	0.65	0.66	0.56	0.48	0.68	0.64	0.65	0.77	0.72
F7	0.42	0.41	0.42	0.39	0.41	0.42	0.42	0.59	0.73	0.59
F8	0.51	0.59	0.50	0.60	0.45	0.56	0.56	0.50	0.62	0.68

两种方法对 LTT1 数据集的 8 类故障模式的识别结果如表 3 所示,两个方法对单部件缓变故障识别效果一

样,都能正确识别出 F2、F3、F5、F6、F7 和 F8 故障,两种方法的 *G-mean* 值均为 0.9740。

表 3 两种方法对 LTT1 数据集诊断结果

Table 3 Diagnosis results of two models on LTT1 data set

方法	缓变故障								<i>G-mean</i> 值
	F1	F2	F3	F4	F5	F6	F7	F8	
DTW	9	10	10	9	10	10	10	10	0.9740
本文模型	9	10	10	9	10	10	10	10	0.9740

2) 多部件缓变故障识别

LTT2 数据集涵盖了单部件缓变故障(F1、F2、F3、F4、F6、F7、F9 和 F10)以及多部件并发故障(F11 和 F12)的监测数据、不同工况下相同故障对应的监测数据(F2 和 F9、F6 和 F10),分别将本文模型和 DTW 算法对 LTT2 中的故障进行诊断,结果如表 4 所示。

表 4 两种方法对 LTT2 数据集诊断结果

Table 4 Diagnosis results of two models on LTT2 data set

方法	缓变故障										<i>G-mean</i> 值
	F1	F2	F3	F4	F6	F7	F9	F10	F11	F12	
DTW	9	10	10	10	10	9	9	8	8	8	0.9061
本文模型	10	10	10	9	10	10	10	10	9	8	0.9575

以 F9 类缓变故障为例,本文模型计算得到 F9 类和样本的最小规整距离如表 5 所示。

表 5 F9 类缓变故障数据和样本的最小规整距离(本文模型)

Table 5 Minimum warp distance between F9 gradual changing fault data and samples (the proposed model)

样本	待诊断序列序号									
	1	2	3	4	5	6	7	8	9	10
F1	1.23	0.91	1.09	1.07	1.07	1.16	1.06	1.25	1.18	0.95
F2	0.97	0.96	0.92	0.92	0.82	1.00	0.92	0.54	0.63	0.61
F3	1.46	1.23	0.94	1.17	1.21	1.50	1.40	0.75	0.83	0.69
F4	1.40	0.70	1.11	1.02	0.87	1.53	1.66	0.93	0.87	0.64
F6	1.05	0.72	0.80	0.72	0.64	1.17	1.21	0.76	0.65	0.93
F7	1.55	1.17	1.20	0.78	1.07	1.56	1.26	0.60	0.63	0.85
F9	0.26	0.28	0.30	0.38	0.32	0.26	0.22	0.26	0.32	0.28
F10	0.37	0.59	0.66	0.69	0.61	0.30	0.46	0.34	0.40	0.34
F11	0.75	0.50	0.46	0.54	0.57	0.85	0.75	0.40	0.42	0.45
F12	0.88	0.50	0.73	0.51	0.56	0.95	0.76	0.56	0.56	0.57

由两种方法计算得到的待识别序列和样本最小规整距离可知,本文模型对 10 种缓变故障中的单部件故障都能识别,对于不同工况的相同故障(如工况 1 下的风扇叶间隙 F2 和工况 2 下的风扇叶间隙 F9、工况 1 下的高压涡轮叶间隙 F6 和工况 2 下的高压涡轮叶间隙 F10)也能按工况正确识别。

对 LTT2 中数据,本文模型将 1 个高压压气机叶间隙和高压涡轮叶间隙并发故障误判为风扇叶间隙故障,将 2 个风扇叶间隙和高压涡轮叶间隙并发故障误判为风扇叶面污垢故障,其它类型缓变故障都能正确诊断;DTW 算法对 F2、F3、F4、F5 和 F6 故障能够正确识别,而某些单部件故障(如风扇叶面污垢、低压涡轮叶面污垢)会被误判为风扇、高压压气机和高压涡轮部件并发故障,高压涡轮和高压压气机部件并发故障又被识别为单部件故障以及风扇部件和高压涡轮部件并发故障。相对 DTW 算法,本文模型虽然将多部件并发故障识别为单部件故障,但是整体对这几种故障的定位大都准确到了部件级,可向机务人员提供维修指导,减少机务人员不必要的检查工作。

2.2 真实数据实验

1) 发动机本体缓变故障识别

收集并整理了某航空公司 2002~2008 年的共 24 台 CFM56 型航空发动机的监测数据,采样点间隔 200 个飞行循环。这些退化数据按故障分为 3 组:叶片和高压涡轮罩损伤(RF1,共 10 台)、轴承损伤(RF2,共 7 台)、滑油泄露(RF3,共 7 台)。选取排气温度裕度(exhaust gas temperature margin, ECTM)、高压压气机转子角速度偏差量(delta N2, DN2) 和平均滑油消耗率(average oil consumption, AOC)3 个监测参数来进行识别。

分别采用 DTW 算法和本文模型对 24 台发动机进行故障诊断。具体做法:取某台发动机退化数据作为待识别序列,剩余的 23 台性能数据则作为样本,一一比对以确定相应故障模式。两种方法对这组真实数据诊断结果如表 6 所示,和仿真数据结果相比,对这组真实数据本文模型和 DTW 算法诊断效果有很大下降。

表 6 两种方法诊断结果

Table 6 Diagnosis results of two models

方法	RF1	RF2	RF3	G-mean 值
DTW	4	4	3	0.418 8
本文模型	6	4	3	0.527 7

通过查看这组真实数据,发现 3 类故障对应退化数据的平均采样点分别为 38、28、19,每个采样点间隔 200 飞行循环;按照实际工作中约 1 个月 150 个飞行循环,一般 2~3 个月的连续数据能看出发动机状态发展趋势,而这组数据两个采样点跨度一个多月,丢失了很多发动机状态变化的信息,并且加上航线水洗等操作,使得这组数据并不能真正表现发动机状态的演化,并且这组数据只是考虑了 3 个性能监测参数,信息量也低于仿真数据,所以故障诊断效果很差。

2) 缓变故障状态和正常状态的识别

为了进一步考察本文模型的工程实用性,又收集了

2011~2012 年某航空公司 CFM56 型发动机的巡航监测数据,包括了因引气系统 TCT 漏气故障(TCT)、EGT 热电偶失效故障(TMP)、HPC 转子叶片损伤(HPC)、VSV 锁子断(VSV) 对应的监测数据和发动机正常状态(nonF)数据。因为实际使用中发动机本体缓变故障及其他系统故障非常少,所以对选取了 50 组发动机正常状态数据,对故障监测数据进行降采样并添加高斯噪声分别构成了 25 组数据,分别从 nonF 数据和各故障监测数据中随机取 10 组、5 组作为待识别数据,其余数据作为样本,每个采样点的飞行循环间隔不超过 2 个飞行循环;监测参数包括 DEGT、DN2、DFF、OIP(滑油压力)、OIT(滑油温度)、吊架温度、HPT 活门位置共 7 个参数。本文模型和 DTW 算法的诊断结果如表 7 所示。

表 7 两种方法对真实数据诊断结果

Table 7 Diagnosis results of two models on real data

方法	nonF	TCT	TMP	HPC	VSV	G-mean 值
DTW	5	1	3	0	0	0.433 8
本文模型	10	5	5	5	5	0.914 6

本文模型 G-mean 值为 0.9146,能够将发动机正常状态数据和故障对应的监测数据区分开来,将 TCT 阀门松和 EGT 热电偶坏故障误识别为其它故障;DTW 算法 G-mean 值为 0.433 8,它将 2 个正常状态识别为故障,对 VSV 锁子断识别较好,而对其它模式识别效果非常差,甚至将故障对应的监测数据序列判断为正常性能退化。就工程应用而言,如果早期能根据监测数据判断缓变故障类型,则机务人员会进行排故操作,从而保证飞机安全性,因此本文模型更可靠。

3 结论

本文研究了发动机性能退化导致的缓变故障诊断问题,提出了利用 CTW 算法进行航空发动机缓变故障诊断。经过仿真数据和真实数据的实验,得到如下结论。

1) 利用相关时间规整算法可解决航空发动机缓变故障诊断问题,该方法对监测数据要求时间粒度越细越好,本文实验数据的时间间隔均是 1~2 个飞行循环,因为间隔越大,发动机状态过渡信息越少,则会导致识别效果降低。

2) 提出的航空发动机退缓变故障诊断模型能够利用航空发动机状态的过渡信息,充分挖掘发动机的性能演化信息,能有效区分正常状态和缓变故障类型,并且对于并发故障和单部件故障能够定位到部件级。

3) 数据点间隔满足 1~2 个飞行循环前提下,该模型根据有噪声干扰的仿真数据和真实数据进行发动机缓变

故障诊断的 $G - mean$ 值平均为 0.948 7, 而 DTW 算法只有 0.771 3, 提高了发动机故障诊断的灵活性和有效性, 对工程应用有很大的应用指导价值。

参考文献

- [1] 李晗, 萧德云. 基于数据驱动的故障诊断方法综述[J]. 控制与决策, 2011, 26(1):1-9.
- LI H, XIAO D Y. Survey on data driven fault diagnosis methods [J]. Control and Decision, 2011, 26(1):1-9.
- [2] 李娟, 周东华, 司小胜, 等. 微小故障诊断方法综述[J]. 控制理论与应用, 2012, 29(12): 1517-1529.
- LI J, ZHOU D H, SI X SH, et al. Review of incipient fault diagnosis methods [J]. Control Theory and Applications, 2012, 29(12): 1517-1529.
- [3] DAI X, GAO Z. From model, signal to knowledge: A data-driven perspective of fault detection and diagnosis[J]. IEEE Transactions on Industrial Informatics, 2013, 9(4):2226-2238.
- [4] 周东华, 刘洋, 何潇. 闭环系统故障诊断技术综述[J]. 自动化学报, 2013, 39(11):1933-1943.
- ZHOU D H, LIU Y, HE X. Review on fault diagnosis techniques for closed-loop systems[J]. Acta Automatica Sinica, 2013, 39(11):1933-1943.
- [5] QIAO W, LU D. A survey on wind turbine condition monitoring and fault diagnosis—Part II: Signals and signal processing methods [J]. IEEE Transactions on Industrial Electronics, 2015, 62(10): 6546-6557.
- [6] 张可, 周东华, 柴毅. 复合故障诊断技术综述[J]. 控制理论与应用, 2015 (9):1143-1157.
- ZHANG K, ZHOU D H, CHAI Y. Review of multiple fault diagnosis methods [J]. Control Theory and Applications, 2015 (9):1143-1157.
- [7] 宋征宇. 运载火箭远程故障诊断技术综述[J]. 宇航学报, 2016, 37(2): 135-144.
- SONG ZH Y. The survey of launch vehicle long distance fault diagnosis technique [J]. Journal of Astronautics, 2016, 37(2): 135-144.
- [8] 文成林, 吕菲亚, 包哲静, 等. 基于数据驱动的微小故障诊断方法综述[J]. 自动化学报, 2016, 42(9): 1285-1299.
- WEN CH L, LV F Y, BAO ZH J, et al. A review of data driven-based incipient fault diagnosis [J]. Acta Automatica Sinica, 2016, 42(9): 1285-1299.
- [9] 石明江, 罗仁泽, 付元华. 小波和能量特征提取的旋转机械故障诊断方法[J]. 电子测量与仪器学报, 2015, 29(8): 1114-1120.
- SHI M J, LUO R Z, FU Y H. Fault diagnosis of rotating machinery based on wavelet and energy feature extraction[J]. Journal of Electronic Measurement and Instrumentation, 2015, 29(8): 1114-1120.
- [10] 武哲, 杨绍普, 刘永强. 基于多元经验模态分解的旋转机械早期故障诊断方法[J]. 仪器仪表学报, 2016, 37(2): 241-248.
- WU ZH, YANG SH P, LIU Y Q. Rotating machinery early fault diagnosis based on multivariate empirical mode decomposition [J]. Chinese Journal of Scientific Instrument, 2016, 37(2): 241-248.
- [11] FENG Z, CHEN X, LIANG M. Joint envelope and frequency order spectrum analysis based on iterative generalized demodulation for planetary gearbox fault diagnosis under nonstationary conditions[J]. Mechanical Systems and Signal Processing, 2016, 76-77 (8): 242-264.
- [12] 孔祥振. 基于经验模态分解与 BP 神经网络的滚动轴承故障诊断[D]. 青岛: 山东科技大学, 2014.
- KONG X ZH. Rolling bearing fault diagnosis based on EMD and BPNN [D]. Qingdao: Shandong University of Science and Technology, 2014.
- [13] WONG P K, YANG Z, VONG C M, et al. Real-time fault diagnosis for gas turbine generator systems using extreme learning machine[J]. Neurocomputing, 2014, 128(5): 249-257.
- [14] 陈绍炜, 柳光峰, 治帅, 等. 基于蝙蝠算法优化 ELM 的模拟电路故障诊断研究[J]. 电子测量技术, 2015, 38(2): 138-141.
- CHEN SH W, LIU G F, YE SH, et al. Research for analog circuit fault diagnosis based on ELM optimized by bat algorithm[J]. Electronic Measurement Technology, 2015, 38 (2): 138-141.
- [15] 崔建国, 严雪, 蒲雪萍, 等. 基于动态 PCA 与改进 SVM 的航空发动机故障诊断[J]. 振动、测试与诊断, 2015, 35(1): 94-99.
- CUI J G, YAN X, PU X P, et al. Aero-engine fault diagnosis based on dynamic PCA and improved SVM [J]. Journal of Vibration, Measurement and Diagnosis, 2015, 35(1):94-99.
- [16] 马继昌, 司景萍, 牛嘉骅, 等. 基于自适应模糊神经网络的发动机故障诊断[J]. 噪声与振动控制, 2015, 35(2): 165-169.
- MA J CH, SI J P, NIU J Y, et al. Engine fault diagnosis based on adaptive fuzzy neural network [J]. Noise and Vibration Control, 2015, 35(2):165-169.
- [17] 李丽敏, 王仲生, 姜洪开. 基于相似性传播聚类的航空发动机突发故障诊断[J]. 振动与冲击, 2014, 33(1): 51-55.
- LI L M, WANG ZH SH, JIANG H K. Abrupt fault diagnosis of aero-engine based on affinity propagation

- clustering [J]. Journal of Vibration and Shock, 2014, 33(1) : 51-55.
- [18] MORALES V L. Sistemas de clasificación basados en reglas difusas para problemas no balanceados. Aproximaciones y uso de nuevas estrategias para resolver problemas intrínsecos a los datos no balanceados [D]. Granada: Universidad de Granada, 2014.
- [19] LOYOLA-GONZÁLEZ O, MARTÍNEZ-TRINIDAD J F, CARRASCO-OCHOA J A, et al. Study of the impact of resampling methods for contrast pattern based classifiers in imbalanced databases [J]. Neurocomputing, 2016, 175(B) : 935-947.
- [20] GUPTA A, SAMANTA A N, KULKARNI B D, et al. Fault diagnosis using dynamic time warping [C]. International Conference on Pattern Recognition and Machine Intelligence, 2007: 57-66.
- [21] 白志强, 唐永哲. 基于动态时间规整的飞控系统故障诊断 [J]. 计算机仿真, 2007, 24 (1) : 39-41.
BAI ZH Q, TANG Y ZH. Fault detection of F light control system based on DTW [J]. Computer Simulation, 2007, 24 (1) : 39-41.
- [22] 胡小平, 韩泉东, 李京浩. 结合动态时间弯曲与决策树方法的液体火箭发动机故障诊断 [J]. 国防科技大学学报, 2007, 29 (4) : 2-2.
HU X P, HAN Q D, LI J H. Fault diagnosis of liquid rocket engine by dynamic time warping combined with decision tree method [J]. Journal of National University of Defense Technology, 2007, 29 (4) : 2-2.
- [23] SINGH V, MEENA N. Engine fault diagnosis using DTW, MFCC and FFT [C]. Proceedings of the First International Conference on Intelligent Human Computer Interaction, Springer India, 2009: 83-94.
- [24] ZHEN D, WANG T, GU F, et al. Fault diagnosis of motor drives using stator current signal analysis based on dynamic time warping [J]. Mechanical Systems and Signal Processing, 2013, 34(1) : 191-202.
- [25] DING H, TRAJCEVSKI G, SCHEUERMANN P, et al. Querying and mining of time series data: experimental comparison of representations and distance measures [J]. Proceedings of the VLDB Endowment, 2008, 1 (2) : 1542-1552.
- [26] ZHOU F, DE LA TORRE F. Canonical time warping for alignment of human behavior [C]. International Conference on Neural Information Processing Systems, 2009.
- [27] KUBAT M, HOLTE R C, MATWIN S. Machine learning for the detection of oil spills in satellite radar images [J]. Machine Learning, 1998, 30(2-3) : 195-215.

作者简介



周媛, 2001 年于南京气象学院获得学士学位, 2006 年于南京信息工程大学获得硕士学位, 2016 年于南京航空航天大学获得博士学位, 现为南京信息工程大学讲师, 主要研究方向为航空发动机健康管理及机器学习。

E-mail: zhouyuan@nuist.edu.cn

Zhou Yuan received B. Sc. from Nanjing Institute of Meteorology in 2001, M. Sc. from Nanjing University of Information Science and Technology (NUIST) in 2006, and Ph. D. from Nanjing University of Aeronautics and Astronautics in 2016, respectively. Now she is a lecturer in NUIST. Her main research interests include PHM of aero-engine and machine learning.