

基于径向基神经网络的航空发动机气路故障诊断

赵 军, 侯宽新, 赖安卿

(中国民航飞行学院 航空工程学院, 四川 广汉 618307)

摘要: 基于径向基神经网络对民用高涵道比航空发动机风扇、增压级、高压压气机、高压涡轮、低压涡轮 5 大气路部件的效率降低故障进行诊断; 采用 Gasturb 进行故障训练样本和测试样本库的生成, 诊断结果显示, 采用径向基神经网络进行航空发动机气路故障诊断的计算时间短、精度较高, 不仅能定性的定位故障部位, 而且在大多数情况下可以定量的给出该部件的性能衰退程度; 某些情况下诊断结果与测试样本不尽一致, 但都是方程的合理解, 这是因为航空发动机的数学模型是一个多解的复杂方程, 一个总性能的衰减对应着多组部件性能衰退的组合; 随噪声幅值加大, 诊断精度变差, 同时研究发现诊断精度受噪声影响的敏感系数在不同的噪声幅值水平下是不同的。

关键词: 航空发动机; 气路故障; 径向基; 神经网络; 噪声

Diagnosis of Aero-engine Gas Path Fault Based on Radial-Basis Function Neural Network

Zhao Jun, Hou Kuanxin, Lai Anqing

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

Abstract: Fault diagnosis of five gas path parts such as fan, booster, high-pressure compressor (HPC), high-pressure turbine (HPT), low-pressure turbine (LPT) 's efficiency degradation have been conducted based on Radial-Basis Function (RBF) neural network. The training and testing samples have been generated by Gasturb software. Diagnose result showed RBF neural network has advantage of less-time-costing and high-precision. RBF neural network can not merely isolate the fault parts, also it can determinate the degradation of components performance. In some instances, the diagnostics result doesn't agree with testing sample, but it also is reasonable solution, because the mathematical model of aero-engine is so complicated that the mathematical equation have more than one reasonable solutions. A degradation of gross performance may be caused by several combinations of components performance degradation. With increasing amplitude of noise, precision of diagnostics became worse. Sensitivity coefficient of diagnostics-precision corrupted by noise is variable with different amplitude of noise.

Keywords: aero-engine; gas path fault; RBF; neural network; noise

0 引言

随着航空发动机日趋复杂化、自动化和智能化, 维修人员采用传统方法进行故障诊断具有很大的局限性。发动机智能故障诊断指通过检测发动机的气动热力参数和机械性能参数, 实现对发动机的状态监控, 进而实现对故障的定性、定位、定因。为了提高发动机的使用效率, 降低维护时间和费用, 提高发动机在翼时间, 采用故障智能诊断系统对发动机进行故障诊断是非常必要的。在航空发动机故障中, 气路部件引起的故障约占 90% 的比例, 对其的维护费用也高达发动机总体维护费用的 60%, 因此对航空发动机气路部件故障进行智能诊断是非常必要的^[1]。

国外学者在把神经网络应用于航空发动机气路故障诊断领域开展的研究较早: Torella 介绍了 BP 网络在燃气涡轮发动机诊断上的应用^[2]。Kanelopoulos 介绍了部件和传感器故障诊断

的人工神经网络的架构^[3], 并发现使用多个网络进行故障诊断比采用单一的网络对部件、传感器的故障诊断具有更好的效果。在此之后 Ogaji^[4]采用 rainfall 型网络来隔离部件及传感器故障。同时, 国外发动机制造厂商或专门的服务提供商还开发了商业气路故障诊断程序, 如美国 GE 公司开发的 TEMPER 故障诊断程序^[5-6], 美国 Arnold 工程发展中心开发的实时涡轮发动机诊断系统 RTEDS^[7], 英国 Cranfield 大学开发的 Pythia 故障诊断软件^[8]。

国内在神经网络应用于航空发动机气路故障诊断方面起步较晚。杨海龙^[9]利用 BP 神经网络建立了航空发动机定量故障诊断系统, 采用粒子群优化算法对 BP 神经网络进行了优化, 以提高训练速度和诊断精度。鲁峰^[10]以某型涡扇发动机部件级模型为对象, 开展了以支持向量回归机优化算法进行训练, 并构建性能评估系统, 结果显示该系统在典型点的预测精度较高, 总体上能实现预测。张光明^[11]采用 GSP 仿真软件组建了 JT9D 涡扇发动机的整机仿真模型, 采用共轭梯度法及比例共轭梯度法对 ANFIS 进行改进, 解决了 ANFIS 方法存在的容易陷入局部最小值的缺陷, 同时一定程度上加快了训练速度。彭淑宏^[12]以 PW4000 发动机为例, 首先对 20 个故障模式建立标准故障诊断规则库, 采用 GSP 软件建立发动机仿真模型, 得到训练样本; 在具体实施时, 先通过相似参数进行故障隔

收稿日期: 2016-01-18; 修回日期: 2016-02-24。

基金项目: 国家自然科学基金(51306201); 四川省教育厅自然科学基金项目(16ZB0035); 中国民用航空飞行学院科学研究基金(J2014-38); 中国民用航空飞行学院科学研究基金(J2015-28)。

作者简介: 赵 军(1980-), 男, 安徽淮北人, 高级工程师, 博士, 主要从事的研究方向为航空发动机故障诊断研究。

离, 之后在部件级子网络中应用 RBF 神经网络进行故障模式的辨识和严重程度的确定。李业波^[13]采取将两个诊断模块定量融合的技术途径, 结合了两种算法的优点, 进而提高了诊断的可靠性及精度。孙斌^[14]开展了 BPN 在涡扇发动机气路故障诊断中的应用, 郝英^[15]开展了航空燃气涡轮发动机气路故障诊断现状的分析和未来技术发展的展望。

由于 RBF (radial basis function) 神经网络输出与网络的连接权值是线性关系, 这使估计方法简化, 避免学习中反复迭代过程, RBF 神经网络收敛速度比改进的 BP 神经网络快很多, 并且 RBF 神经网络比 BP 神经网络的稳定性更好。同时 RBFNN 具有很好的抗干扰能力, 它还具有唯一最佳逼近点的优点, 这点是容易陷入局部最小值的 BP 神经网络所欠缺的, 鉴于此, RBF 网络正在越来越多的领域取代了 BP 网络。现在故障诊断领域新的方法层出不穷, 涌现出很多的算法如 KNN, LSVM, NSVM, HSVMkSIR 等^[16], 可谓是琳琅满目, 鉴于 RBF 的良好特性和很少的计算时间, 尽管不是新的算法, 本文依然选择 RBF 神经网络作为故障诊断的工具。

应用 RBF 神经网络进行故障诊断时需要训练样本的支持, 要求训练样本具备遍历性、致密性和相容性。训练样本是否具备这三性对 RBF 故障诊断的成功率是至关重要的。而工程实际中故障样本的获取受到各方面的限制, 不是数目不够, 就者故障特征的描述精度不够, 或者数据不齐全。由德国 MTU 公司 Kurzke 博士开发的 Gasturb 软件在航空发动机整机总体性能分析领域得到了广泛的应用与认可。为获取足够的故障样本, 作者采用 Gasturb 分析软件对该发动机的 3 个巡航阶段监控性能参数受各部件效率影响进行分析, 并获得大量的训练样本和测试样本, 降低了工程实际故障样本数获取过少以至难以提高诊断成功率的技术风险。

本文采取 RBF 神经网络进行民用高涵道比航空发动机气路故障诊断, 而故障模式则定位在风扇、增压级、高压压气机、高压涡轮、低压涡轮 5 大气路部件的效率降低。首先采用 Gasturb 软件进行故障训练和测试样本库的生成, 然后基于 MATLAB 神经网络工具箱进行故障诊断, 最后进行故障诊断成功率的分析和噪声的影响分析。

1 某航空发动机故障样本获取

GASTURB 软件是一款优秀的航空发动机总体性能计算软件, 可以便捷的进行发动机总体性能参数的计算。首先建立某民用高涵道比涡扇发动机的整机数学模型, 在此基础上修改 5 个气路部件 (风扇、增压级、高压压气机、高压涡轮、低压涡轮) 的效率, 得到对应的总体性能输出。

任何气路诊断技术都是利用发动机可观测参数与厂家提供的发动机基线数据进行对比, 根据比较出来的偏差进行故障诊断。本文可观测参数的选取参考 GE 公司民航发动机远程监控软件 Remote Diagnosits 的做法, 选取 EGT (exit gas temperature, 排气温度), FF (fuel flow, 燃油流量), N2 (高压转子转速) 这 3 个性能参数。

在进行训练样本生成时, 仅考虑发动机保持在巡航状态, 飞行高度 35 000 ft, 飞行速度 0.8 Ma, 低压轴转速为 90% N1max, 同时控制系统为单变量控制系统, 控制量为主燃油流量, 被控参数为低压轴转速 (N1)。稳态下的控制规律为: 调节主燃油流量控制发动机低压轴转速 N1 保持不变。从 5 个气路部件中任意选取 2 个构成一组故障样本, 每组故障样本定义两个部件的效率分别为 -5 pt, -4 pt, -3 pt, -2 pt, -1 pt, 0, 其中 0 代表设计状态的效率, 其他 3 个部件的效率取为 0, 即无故障状态。这样每组故障样本就包含了 6 * 6 = 36 个故障样本。故障样本的组数为 C (5, 2) = 10 个 (计算公式 $C(m, n) = m! / \{n! * (m - n)!\}$)。所以故障样本的总数为 36 * 10 = 360 个, 考虑到 {0 0 0 0 0} 在 10 组样本中都存在, 重复了 9 次, 所以有效的训练样本为 351 个。本文所用的训练样本全部来自 Gasturb 的仿真数据, 工程实际中故障样本的获取受到各方面的限制, 如样本数少、精度差, 或者就是仅有总体性能参数偏差而没有部件性能偏差, 而如果要补齐部件性能的偏差量则动辄需要上千万的部件实验费用。

在进行测试样本生成时, 为保证训练样本的遍历性, 选取 -4.5 pt, -3.5 pt, -2.5 pt, -1.5 pt, -0.5 pt 作为 GASTURB 软件的输入, 得到相应的总体性能参数的输出。本文从中选取 12 个测试样本作故障诊断结果分析用。下表 1 给出了从 351 个训练样本中随机抽取的 7 个样本, EGT 是当前状态下的排气温度与无故障状态下排气温度差值除以 10 得到的; FF 与 N2 是当前状态下的燃油流量、高压转子转速与无故障状态 (基线模型) 下的相对变化率, 以百分数表示。分别用 $\eta_1, \eta_2, \eta_3, \eta_4, \eta_5$ 来代表风扇、增压级、高压压气机、高压涡轮、低压涡轮的效率降低。从前 6 个样本可以看出, 当风扇效率保持不变, 增压级效率降低时, EGT 升高, FF 与 N2 也都呈现升高的趋势; 第 7 个样本为发动机的基线状态, 即各部件工作正常, 3 个性能参数也正常, 偏差量均为 0。

表 2 给出了全部测试样本。从表中可以看出低压轴上的风扇、增压级效率降低会增加 N2 转速; 而高压轴上的高压压气机、高压涡轮的效率降低会导致 N2 转速的下降, 这和该款发动机以 N1 作为被控参数的控制规律有关。

表 1 部分训练样本

训练样本	η_1	η_2	η_3	η_4	η_5	EGT(K)	FF/%	N2/%
1	-5.000	-5.000	.000	.000	.000	3.920300	8.631273	3.011392
2	-5.000	-4.000	.000	.000	.000	3.441919	7.871192	2.706160
3	-5.000	-3.000	.000	.000	.000	2.973816	7.128097	2.406617
4	-5.000	-2.000	.000	.000	.000	2.508313	6.394538	2.109901
5	-5.000	-1.000	.000	.000	.000	2.062268	5.697403	1.823371
6	-5.000	.000	.000	.000	.000	1.637189	5.038774	1.547517
7	.000	.000	.000	.000	.000	.000000	.000000	.000000

2 故障诊断介绍

MATLAB 软件在数值计算方面首屈一指，有功能强大的神经网络工具箱和丰富的库函数，利于进行故障诊断程序的编写，作者采用神经网络工具箱中的 newrb 进行该发动机的故障诊断，训练样本数为 351，输入 3 个性能参数（EGT，FF，N2）的偏差量，输出为 5 个气路部件（风扇、增压级、高压压气机、高压涡轮、低压涡轮）气动效率的偏差量。训练过程

如图 1 所示，可以看出经过 320 步的训练，耗时 6 s，残差水平 MSE 达到了 $1.26101\text{e}-011$ ，收敛较好。经过上述学习训练后，网络获取诊断中航空发动机的故障知识以分布在网络内部的连接权值隐性表达。得到训练后的网络，以 sim 命令进行诊断值的计算。

3 故障诊断结果分析

针对 12 个测试样本得到的故障诊断结果如表 3 所示。

表 2 全部测试样本

样本	η_1	η_2	η_3	η_4	η_5	EGT(K)	FF/%	N2/%
T1	-4.500	-4.500	.000	.000	.000	3.5067570	7.707124	2.699579
T2	-4.500	-3.500	.000	.000	.000	3.0339540	6.957963	2.396837
T3	-4.500	-2.500	.000	.000	.000	2.5715940	6.231776	2.100497
T4	-4.500	-1.500	.000	.000	.000	2.1214050	5.529739	1.811378
T5	-4.500	-.500	.000	.000	.000	1.6809200	4.844201	1.527966
T6	-4.000	-4.500	.000	.000	.000	3.3336360	7.168280	2.541652
T7	.000	.000	-3.50	-3.500	.000	11.842770	6.859155	-5.816486
T8	.000	.000	-3.50	-2.500	.000	9.8678960	5.808433	-5.091261
T9	.000	.000	-3.50	-1.500	.000	7.9406490	4.716816	-4.310456
T10	.000	.000	-3.50	-.500	.000	6.0495060	3.611477	-3.434671
T11	.000	.000	-2.50	-4.500	.000	12.217190	7.055266	-5.954871
T12	.000	.000	-2.50	-1.500	.000	6.3567140	3.788986	-3.590900

表 3 故障诊断结果

Result	η_1	η_2	η_3	η_4	η_5	EGT(K)	FF/%	N2/%
R1	-5.02	-4.97	0.09	0.00	0.05	3.5067570	7.707124	2.699579
R2	-4.72	-3.54	0.04	0.00	-0.03	3.0339540	6.957963	2.396837
R3	-4.72	-2.52	0.04	0.00	-0.02	2.5715940	6.231776	2.100497
R4	-4.58	-1.44	-0.00	-0.00	0.03	2.1214050	5.529739	1.811378
R5	-4.10	-0.19	-0.06	-0.00	-0.19	1.6809200	4.844201	1.527966
R6	-0.81	-1.02	-0.39	-0.01	-1.45	3.3336360	7.168280	2.541652
R7	-0.00	0.00	-3.31	-3.43	0.00	11.842770	6.859155	-5.816486
R8	0.00	-0.00	-2.15	-3.51	0.00	9.8678960	5.808433	-5.091261
R9	0.00	-0.00	-4.66	-0.59	-0.00	7.9406490	4.716816	-4.310456
R10	-0.00	0.00	-3.60	-0.33	0.00	6.0495060	3.611477	-3.434671
R11	-0.00	0.00	-2.36	-4.37	0.00	12.217190	7.055266	-5.954871
R12	0.00	-0.00	-2.48	-1.52	-0.00	6.3567140	3.788986	-3.590900

表 4 诊断效果差的对比分析

Index	η_1	η_2	η_3	η_4	η_5	EGT(K)	FF/%	N2/%
T1	-4.500	-4.500	.000	.000	.000	3.5067570	7.707124	2.699579
R1	-5.02	-4.97	0.09	0.00	0.05	3.5067570	7.707124	2.699579
R1 *	-5.00	-5.00	0.00	0.00	0.00	3.920300	8.631273	3.011392
T6	-4.000	-4.500	.000	.000	.000	3.3336360	7.168280	2.541652
R6	-0.81	-1.02	-0.39	-0.01	-1.45	3.3336360	7.168280	2.541652
T8	.000	.000	-3.500	-2.500	.000	9.8678960	5.808433	-5.091261
R8	0.00	-0.00	-2.15	-3.51	0.00	9.8678960	5.808433	-5.091261
R8 *	0.00	0.00	-2.00	-3.50	0.00	9.418152	5.555665	-4.931059
T9	.000	.000	-3.500	-1.500	.000	7.9406490	4.716816	-4.310456
R9	0.00	-0.00	-4.66	-0.59	-0.00	7.9406490	4.716816	-4.310456
R9 *	0.00	0.00	-4.50	-0.50	0.00	7.650153	4.552792	-4.175697




图 1 训练过程

为便于对诊断结果的优劣进行量化, 本文采用卡尔·皮尔逊设计的 Pearson 相关系数的处理方法, Pearson 相关系数的绝对值越大, 代表两个向量间的相关性越强, 相关系数越接近于 1 或 -1, 相关度越强。图 2 示出了 12 个诊断结果的相关系数分布。可以看到, 除 R6, R8, R9 外其他测试样本相关度非常接近 1, 反应出较高的诊断精度。R₁ 也存在一个典型的问题, 下面我们来分析 4 个样本 R₁, R6, R8, R9。




图 2 诊断结果的相关系数分布

表 4 给出了 4 个测试样本与诊断结果的对比, 其中 T_n 为给定的测试样本, 而 R_n 为故障诊断的结果, R_n^* 为与 R_n 相邻的训练样本。图 3 则给出了 4 个测试样本与诊断结果的 5 个效率偏差分量对比图。

从 R₁ 可以看出, 网络在诊断时沿高压压气机、低压涡轮气动效率增加的方向搜索, 反映出 RBF 的外向插值功能; 但从定性的角度考虑或者采用分量排序法, 诊断结果足以指导排故工作的。从 R₈ * 可以看出, 训练样本 R₈ * 的性能指标与 T₈ 的性能指标较为接近, 网络在 R₈ * 附近搜索, 找到了 R₈, 这也是一个合理解, 说明该发动机的数学模型是一个多解方程, 一个总性能的衰减对应着多组部件性能衰退的组合; 从测试样本 T₉, 诊断结果 R₉ 以及训练样本 R₉ * 的对比中也可以

看到这种趋势。从图 3 (b) 的对比可以看出, 诊断结果 R₆ 与测试样本 T₆ 差别较大, 导致图 2 中相关系数仅有 0.3。T₆ 中只有两个部件存在性能衰退, 而 R₆ 中得到了四个部件的性能衰退 (高压涡轮 0.01 可以忽略不计), 这同样说明 R₆ 也是对应总性能衰退下的部件性能衰退合理组合解, 而这种较差的诊断案例可以通过提高训练样本的致密度来有效消除。




图 3 四个测试样本与诊断结果的对比

从诊断结果可以看出, 采用 RBF 神经网络进行故障诊断的精度较高, 在诊断多故障并存的故障模式时, 不仅能定性的定位故障部位, 而且在大多数情况下可以定量的给出该部件的性能衰退程度。

4 考虑噪声的故障诊断分析

工程实际中, 性能参数的偏差量的处理过程如图 4 所示分为测量、换算、与基线对比得到偏差量、归一化、诊断 5 个步骤。其中第 1 步的测量过程中不可避免的会引入一定程度的噪

声, 这些噪声会污染数据, 降低故障诊断成功率。一般都会通过对测量数据序列采用移动平均平滑法或指数平滑法来过滤噪声, 或更加复杂的滤波技术来降低观测噪声对估计结果的影响。本文因研究方式所限, 总体性能参数是通过 Gasturb 仿真得到, 没有测量数据序列, 为研究噪声对诊断结果的影响, 从第 3 步引入虚拟噪声, 通过输出中添加不同幅值的随机噪声信号 (MATLAB 中 randn 函数) 来研究噪声对诊断结果的影响程度。这里我们用训练误差和检验误差的均方值来宏观的表征诊断精度。





图 4 故障诊断的流程

诊断后得到的训练误差和检验误差的均方值如表 5 所示, 绘图如图 5 所示, 可以看到, 随着噪声幅值的增加, 训练误差和检验误差的均方值也随之增加。


表 5 训练误差和检验误差的均方值

Index	噪声水平	训练误差均方值	检验误差均方值
1	2e-4	3.83E-10	0.0314
2	2e-3	6.17E-10	0.036
3	2e-2	1.22E-08	0.8712
4	2e-1	1.08E-07	8.9392

表 6 给出了 3 个变化过程中的噪声幅值、训练误差和检验误差的均方值的增加倍数。过程 1~4 中噪声强度增加了 1 000 倍, 训练误差均方值增加了 282 倍, 而检验误差均方值增加了 285 倍。绘图如图 6 所示。图中可见, 3 个变化过程中尽管噪声幅值增加幅度保持一致, 而训练误差均方值的增加幅度非恒定值, 而是在 2~3 的过程中增加倍数最大, 检验误差均方值的增加幅度也呈现出同样的特征, 说明了径向基神经网络的诊断结果受信号噪声幅值的敏感系数不同。具体表现为: 在 1~2 阶段每单位噪声幅值降低会带来检验误差均方值降低 0.114 65 (1.146 5/10) 倍; 而在 2~3 阶段每单位噪声幅值降低会带来检验误差均方值降低 2.42 (24.2/10) 倍。在 2~3 阶段降噪的收益比 1~2 阶段的收益要大得多。这将给以后的数据降噪处理一些启发。



(a) 训练误差的均方值



(b) 检验误差的均方值

图 5 不同噪音水平下训练误差和检验误差的均方值

表 6 噪声幅值、训练误差和检验误差的均方值的变化斜率

过程	噪声幅值变化	训练误差均方值的变化斜率	检验误差均方值的变化斜率
1~2	10	1.611	1.1465
2~3	10	19.7731	24.2
3~4	10	8.8525	10.2608
1~4	1000	282	285




图 6 训练误差和检验误差的均方值斜率对比

5 总结

本文以商用大涵道比涡扇发动机作为研究对象, 通过建立其仿真模型, 得到训练和测试样本, 并结合径向基神经网络气路故障诊断技术, 进行诊断精度验证, 并创新性的开展了诊断结果受噪声幅值影响的敏感性分析, 得到以下结论:

(1) 采用 GASTURB 软件进行故障训练和测试样本库的生成在故障诊断算法的前期测试上是非常有效的, 降低了工程实际故障样本数获取过少以至难以提高诊断成功率的技术风险;

(2) 采用 RBF 神经网络进行故障诊断计算快速, 且诊断精度较高, 在诊断多故障并存的故障模式时也可以定量的给出该部件的性能衰退程度; 某些情况下诊断结果与测试样本不尽

一致, 源于航空发动机的数学模型是一个多解的复杂方程, 一个总性能的衰减对应着多组部件性能衰退的组合;

(3) 随噪声幅值加大, 诊断精度变差, 同时发现诊断精度受噪声影响的敏感系数在不同的噪声幅值水平下是不同的;

(4) 工程实际中故障样本的获取受到各方面的限制, 如样本数少、精度差, 或者就是仅有总体性能参数偏差而没有部件性能偏差, 本文以 GasTurb 仿真来构建训练和测试样本, 后续将考虑引入试车数据和民航公司实际运营的发动机测量数据进行数据整理和故障诊断的研究。

参考文献:

[1] Garg S. Controls and Health Management Technologies for Intelligent Aerospace Propulsion Systems [R]. Reston. AIAA - 2004 - 0949.

[2] Torella G, Lombardo G. Utilization of Neural-Networks for Gas-Turbine Engines [J]. XIIISABE 1995, 95 - 103.

[3] Kanelopoulos K, Stamatis A, Mathioudakis K. Incorporating Neural-networks into Gas-turbine Performance Diagnostics [R]. ASME 97-GT-35.

[4] Ogaji S. Advanced Gas-path Fault Diagnostics for Stationary Gas-turbines [D]. England; Cranfield University, 2003.

[5] Doel D L. Interpretation of Weighted-least-squares Gas Path Analysis Results. ASME Paper, J. Eng. Power [J]. 2003, 125: 624 - 633.

(上接第 75 页)

表 6 引入视觉定位的装配结果 pixel			
	第一次	第二次	第三次
圆片 1	793.483,607.245	793.756,606.782	793.231,606.965
圆片 2	793.456,607.172	793.598,607.457	793.573,607.187
圆片 3	793.504,607.163	793.396,606.998	793.513,607.152
圆片 4	793.688,607.056	793.386,607.167	793.494,607.177
圆片 5	793.505,607.029	793.660,607.280	793.614,607.035
圆片 6	793.537,607.248	793.341,607.047	793.702,607.107
圆片 7	793.756,607.017	793.409,607.149	793.384,607.149
同轴度	0.256(0.006mm)	0.498(0.011mm)	0.480(0.01mm)

由表 5、表 6 中的同轴度数据可知, 未引入视觉定位系统时, 装配同轴度误差最大达到 0.356 mm, 而引入视觉定位系统时, 装配同轴度误差最大只有 0.011 mm, 小于 0.05 mm, 满足装配同轴度精度的要求。

4 结论

本文基于机器视觉搭建的高精度测量与装配系统, 通过结合 Canny 算法以及椭圆曲线拟合法, 提取了零件亚像素精度边缘, 为零件尺寸的高精度测量以及零件的高精度装配奠定了基础, 通过分析对比张正友相机标定法与 RAC 标定法的标定结果, 得出采用 RAC 法标定花费的时间比张正友法少, 但前者的精度没有后者高。最终本系统获得的零件尺寸测量精度以及装配同轴度精度均满足工业要求, 可以解决实际问题。

[6] Doel D L. An assessment of Weighted Least-squares-based Gas Path Analysis. ASME Paper, J. Eng. Power [J]. 1994, 116: 366 - 373.

[7] Biejford R, Malloy D. Development of a Real-time Turbine Engine Diagnostic System [A]. 38th AIAA/ASME/SAE/ASEE Joint Propulsion Conference and Exhibit [C]. 2002.

[8] Li Y G, Singh R. An Advanced Gas Turbine Gas Path Diagnostic System-Pythia [A]. 17th Symposium on Air Breathing Engines [C]. 2005.

[9] 杨海龙. 基于智能技术的航空发动机气路故障诊断 [D]. 南京: 南京航空航天大学, 2008.

[10] 鲁 峰, 黄金泉. 航空发动机部件性能参数融合预测 [J]. 航空学报, 2009, 30 (10): 1795 - 1800.

[11] 张光明. 航空发动机气路故障诊断技术研究 [D]. 沈阳: 沈阳航空工业学院, 2010.

[12] 彭淑宏. 航空发动机气路故障诊断技术研究 [D]. 上海: 上海交通大学, 2012.

[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] 孙 斌, 张 津, 张绍基. BPN 在涡扇发动机气路故障诊断中的应用 [J]. 航空动力学报, 13 (3), 1998, 323 - 326.

[15] 郝 英, 孙健国, 白 杰. 航空燃气涡轮发动机气路故障诊断现状与展望 [J], 航空动力学报, 18 (6), 2003, 753 - 760.

[16] Link C. Jaw, Yuh-Jye Lee. Engine Diagnostics in the eyes of Machine Learning [R]. ASME paper GT2014-27088.

参考文献:

[1] 王冠英, 胡心平, 刁维龙. 基于机器视觉的复杂形状模具尺寸测量 [J]. 计算机测量与控制, 2015, 23 (3): 706 - 708.

[2] 查 英, 刘铁根, 杜 东, 等. 基于机器视觉的零件自动装配系统 [J]. 天津大学学报, 2006, 39 (6): 722 - 726.

[3] 李钊宝, 汪新新, 贾茜媛. 基于机器视觉的工件尺寸高精度测量方法 [J]. 计算机测量与控制, 2015, 23 (6): 1866 - 1870.

[4] 郭 瑞, 刘振国, 曹翔翔, 等. 基于视觉的装配机器人精确定位研究 [J]. 制造业自动化, 2014, 36 (5): 154 - 156.

[5] Casten Steger, Markus Ulrich, Christian Wiedemann. Machine Vision Algorithms and Applications [M]. 1sted. , Yang Shaorong, Wu Dijing, Duan Deshan, translated. Beijing: Tsinghua University Press, 2008: 97 - 125.

[6] 张丽群. 基于相关法的多重成像亚像素定位算法的研究与实现 [D]. 哈尔滨: 哈尔滨工程大学, 2005.

[7] 解则晓, 辛少辉, 李绪勇, 等. 基于单目视觉的机器人标定方法 [J]. 机械工程学报, 2011, 47 (5): 35 - 39.

[8] 赵高长, 武风波, 周 彬, 等. 基于 DLT 模型的摄像机标定简化方法 [J]. 应用光学, 2009, 30 (4): 585 - 589.

[9] 张 娜. 摄像机标定方法的研究 [D]. 南京: 南京理工大学, 2014.

[10] Lanser S. Model-based localization based on monocular video images [D]. Technical University of Munich, 1997.

[11] Zhang Z Y. A flexible new technique for camera calibration [J]. IEEE Transactions on Patten Analysis and Machine Intelligence, 2000, 22 (11): 1330 - 1334.