

基于孔探图像纹理特征的航空发动机损伤识别方法

陈 果, 汤 洋

(南京航空航天大学民航学院 南京 210016)

摘 要: 孔探检测是航空发动机视情维修的重要技术,对于正确评估发动机的内部损伤,适时进行发动机修理具有重要意义,但是由于孔探图像的损伤评估往往依赖丰富的专家知识,因此在航空公司飞机多、分布广、专家少的情况下,难于实现发动机损伤的及时评估。本文研究了一种基于孔探图像纹理特征的航空发动机内部损伤评估方法,利用结构自适应神经网络模型,实现了航空发动机孔探图像损伤的自动识别,并进行了必要的验证,结果表明了本文方法的有效性。

关键词: 航空发动机; 孔探检测; 图像纹理; 神经网络

中图分类号: V263.6 TP391.41 TP277 **文献标识码:** A **国家标准学科分类代码:** 460.1540

Aero-engine interior damage recognition based on texture features of borescope image

Chen Guo, Tang Yang

(College of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: Borescope detection is an important means widely applied in the on-condition maintenance of aero-engine. It is very important to evaluate the engine interior damages and repair the faulty engine on time. But the evaluation depends greatly on the experts' experiences so that it is very difficult to carry out evaluation in time because the experts are very few and the aircrafts spread widely. This paper researches an auto-evaluation method for aero-engine interior damages based on borescope image texture features, in which the neural network model with self-adaptive structure is applied to carry out automatic recognition of the damages. Finally, some typical borescope images with damages are used to verify the new method, and the results show its correctness and effectiveness.

Key words: aero-engine; borescope detection; image texture; neural network

1 引 言

现代民航飞机大多使用高涵道比的涡轮风扇发动机,其中核心机部分处在高温、高压、高转速的工作状态下,如不及时发现其中存在的一些故障隐患就会导致灾难性的后果。随着现代科学的发展,发动机维修设备和手段的多样化,采用孔探技术对发动机损伤^[1]、故障隐患进行诊断以及判定损伤等级是新维修方式必不可少的关键环节。目前几乎所有的航空发动机在维护中对核心机的内部检查,尤其是一些不易拆卸且检验可达性较差的零部件都使

用孔探技术来完成。目前的孔探仪经历了从第 1 代硬杆式内窥镜、第 2 代光导纤维内窥镜到第 3 代电子内窥镜的发展,在很大程度上解决了成像质量和损伤尺寸测量的问题^[2-3]。然而,先进的孔探仪对于损伤评估却无能为力,因为损伤评估需要检测人员的丰富的专家经验和知识。而目前航空公司的发动机孔探检测专家往往仅仅限于在专门从事飞机发动机维修的无损检测部门,这种专家少、飞机多、飞机分布广的特点使目前发动机孔探检测面临了典型的异地检测和评估困难问题,无法及时准确地得到评估结果。这就降低了工作效率,增加了营运成本。

有鉴于此,本文研究了一种基于孔探图像纹理特征

的发动机内部损伤的自动识别技术,通过收集典型的损伤图像,提取图像纹理特征,构成训练样本集,利用结构自适应神经网络方法实现纹理特征与损伤类型的非线性映射,从而实现损伤自动识别。

2 航空发动机气路部件的内部损伤类型及评估方法

发动机常见的损伤主要有:裂纹、刻痕、压坑、撕裂、凹痕、烧伤、腐蚀、叶尖卷边。现代飞机大多使用高涵道涡轮风扇发动机,其主要由风扇、压气机、燃烧室、涡轮及附件系统组成。同时,航空发动机工作在高温、高压、高转速的状态下,因此其故障多发部位也多在这三高状态下的高压压气机、燃烧室和高压涡轮中。

1) 高压压气机:主要受到进气道吸进的外来物的冲击、发动机的喘振,导致叶片受损以及疲劳损伤。如果一片叶片断裂,就会打坏后面的几级转子叶片,使发动机空中停车。

2) 燃烧室:由于在高温状态下工作,燃烧室受到的主要损伤是热损伤,如燃烧室烧裂、烧穿和掉块等。其原因有材料、燃料、燃油喷射不均匀以及停车后积油等方面。同时,燃烧室内积炭过多也会影响发动机正常工作,降低燃烧效率。

3) 高压涡轮:由于导向器叶片工作区域温度最高,而且会受到燃烧不均匀、喷油不均匀的影响,因此最容易发生前缘烧熔、后缘断裂、变形及掉块等。除此之外,高压涡轮转子还会因高速旋转而带来损伤,如因燃烧室掉块打伤涡轮转子叶片等,主要表现为前缘卷曲、掉块、烧熔、裂纹、散热孔堵塞、后缘裂纹、积炭等。

在孔探具体实际工作中,首先要解决的工作是要检查出发动机气路关键部件如压气机叶片、涡轮叶片燃烧室等出现的损伤缺陷并拍照,再测量出其尺寸并与手册、工卡给出的标准比较,判断其严重程度、是否超标。判断出是在正常检查值内,还是需缩短检查的监控值内,或是不能再使用的超标值内(这里有 2 种情况:一是超标不能使用立即换下发动机;二是经制造厂家批准给出一个很短的允许使用时间,但在此时间内必须换发)。这都要求工作者须在较短的时间内作出正确判断,提供给相关部门及时而又准确的孔探信息作决策,以避免出现因孔探不正常而错失决策时机,进而造成没有采取正确措施产生飞机在空中被迫关停发动机。

航空发动机损伤评估的关键在于实现损伤类型的自动识别,在获取损伤类型后,结合损伤部位、损伤尺寸及发动机类型等信息,可以很容易作出维修决策。近年来,基于内容的图像检索逐渐成为一个研究的热点^[46]。基于内容的图像检索技术由软件程序智能地提取包含图像

在内的可视特征:如颜色、纹理、形状、对象的位置和相互关系等,通过计算出图像间的特征向量之间的距离来检索出最相似的图像。因此,本文利用基于内容的图像检索思想来实现对图像损伤的识别。研究了基于孔探图像纹理特征的损伤类型识别,而基于颜色及形状特征的损伤识别可以按同样的方法进行分析。

3 基于纹理特征的损伤类型神经网络识别方法

3.1 孔探图像纹理特征参数的计算

考虑到孔探图像的实际情况与复杂性,本文主要提取图像灰度共生矩阵的表面纹理参数作为图像的纹理特征^[7]。将图像 $f(i, j)$ 的灰度归并,其最高灰度为 N_g ,记 $L_x = \{1, 2, \dots, N_x\}$, $L_y = \{1, 2, \dots, N_y\}$ 及 $G = \{1, 2, \dots, N_g\}$ 。因此,可以将待分析的图像 $f(i, j)$ 理解为从 $L_x \times L_y$ 到 G 的一个变换,也就是说对 $L_x \times L_y$ 中的每一点,对应一个属于 G 的灰度。定义方向 θ , 间隔为 d 的灰度共生矩阵为 $[p(i, j, d, \theta)]$ 。

矩阵 $[p(i, j, d, \theta)]$ 的第 i 行 j 列元素表示所有方向,相邻间隔为 d 的像素中有一个取 i 值,另一个取 j 值的相邻对点数。对灰度共生矩阵正规化处理后,可以得到以下几个重要的纹理特征:

1) 角二阶矩:

$$f_1 = \sum_{i=1}^{N_x} \sum_{j=1}^{N_y} \{p(i, j)\}^2 \quad (1)$$

2) 对比度:

$$f_2 = \sum_{i=1}^{N_x-1} \sum_{j=1}^{N_y} n^2 \{p(i, j)\} \quad (2)$$

3) 相关:

$$f_3 = \left\{ \sum_{i=1}^{N_x} \sum_{j=1}^{N_y} i \cdot j \cdot p(i, j) - \mu_x \mu_y \right\} / \sigma_x \sigma_y \quad (3)$$

式中: μ_x 、 σ_x 分别是 $\{p_x(i); i = 1, 2, \dots, N_g\}$ 的均值和均方差; μ_y 、 σ_y 分别是 $\{p_y(i); i = 1, 2, \dots, N_g\}$ 的均值和均方差。其中, $p_x(i) = \sum_{j=1}^{N_y} p(i, j)$, $i = 1, 2, \dots, N_g$; $p_y(i) = \sum_{j=1}^{N_y} p(i, j)$, $j = 1, 2, \dots, N_g$ 。

4) 方差

$$f_4 = \sum_{i=1}^{N_x} \sum_{j=1}^{N_y} (i - \mu)^2 p(i, j) = \sum_{i=1}^{N_x} (i - \mu)^2 p_x(i) \quad (4)$$

式中: μ 是 $p(i, j)$ 的均值。

5) 逆差矩

$$f_5 = \sum_{i=1}^{N_x} \sum_{j=1}^{N_y} \frac{1}{1 + (i - j)^2} p(i, j) \quad (5)$$

显然,上述特征,对于不同的间距 d 和方向 θ 将得到

不同的值。为了获取旋转不变的纹理属性,本文设定 $d=1$,将每一特征 $f_i (i = 1, 2, \dots, 5)$,关于不同的方向 $(0^\circ \leq \theta < 90^\circ \leq 135^\circ)$ 求平均值 \bar{x}_{f_i} 和均方差和 f_i ,这样处理就抑制了方向分量。

3.2 孔探图像损伤识别的集成神经网络模型

本文以 GE90 发动机的孔探图像的 4 类损伤——叶尖卷边、腐蚀、裂纹及撕裂为例进行识别分析,这 4 类损伤分别如图 1 所示。

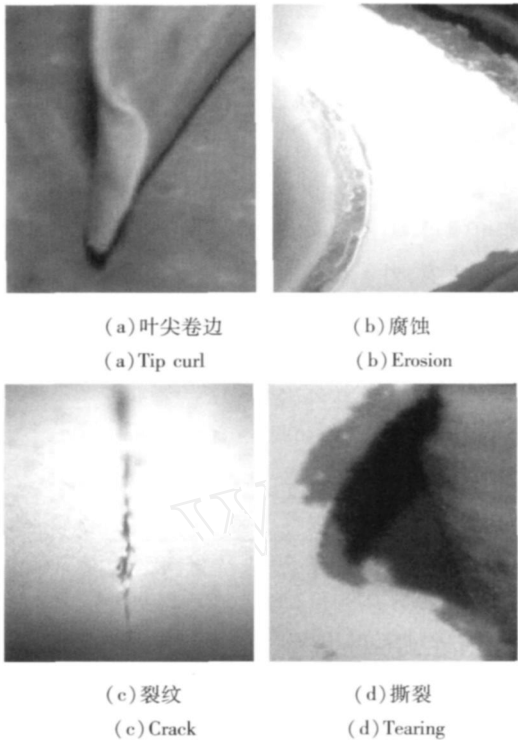


图 1 典型孔探损伤图像

Fig 1 Typical borescope damage images

由于在模式识别中,多类问题往往可以转化为两类问题来处理,而且这样做往往会使网络结构简单,训练样本要求少,训练时间大大缩短。因此,本文建立 4 个子网络来实现对 4 类损伤的识别,每个子神经网络负责识别一种损伤,其结构为一个多输入单输出神经网络。

在每个子网络中, $\{x_1, x_2, \dots, x_{10}\}$ 表示 10 维输入向量,分别代表 10 个纹理特征参数,输入向量需要归一化处理,将数值变换到 0 和 1 之间; y 为输出,代表对应的损伤类型。训练样本的取值为“+1”或“-1”,分别代表是和不是该损伤。神经元激活函数均为双极性 Sigmoid 函数,即:

$$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (6)$$

设单输出子神经网络模型的隐层节点数为 q ,隐层节点的激活函数为 f_H 、阈值为 $\theta_j (j = 1, 2, \dots, q)$;输出层

节点数为 1,隐层节点的激活函数为 f_o 、阈值为 θ 。第 i 个隐节点与第 j 个输入节点的连接权为 w_{ij} ,则第 i 个隐节点与输出节点的连接权为 w_i 。则:

$$y = f_o \left\{ \sum_{i=1}^q W_i f_H \left[\sum_{j=1}^{10} w_{ij} x_j + \theta_i \right] + \theta \right\} \quad (7)$$

由两类分类器原理,根据输出 y 的值来对样本进行判别分类,即: $y > 0$,判断为是该损伤类型; $y < 0$,判断为不是该损伤类型; $y = 0$,则无法判断是否为该损伤。

相同的 10 个纹理参数输入到每个子网络后,每个子网络将产生一个输出 $y_i (i = 1, 2, 3, 4)$,对最终的损伤类型判别方法为:如果 $y_i = \max_{k=1,2,3,4} (y_k)$, and $y_i > 0$, and $N(y_i) = 1$,其中 $N(y_i)$ 表示满足条件的 y_i 的个数。则将最终损伤判别为第 i 类损伤;否则,该样本作拒绝识别处理。

3.3 结构自适应神经网络模型

由于神经网络的结构参数对其泛化能力影响很大,为了充分保证神经网络对损伤识别的精度,本文利用文献 [8] 的结构自适应神经网络方法来构建子网络。

结构自适应神经网络模型以 3 层 BP 网络为研究对象,将神经网络模型分为外部结构参数和内部权值参数。规定为:1)内部参数:网络连接权值,通过对训练样本用神经网络的 BP 算法学习成功后自动产生;2)外部参数:初始权值:影响网络的收敛位置;隐层节点数:直接影响到所逼近的非线性函数复杂程度和模型的泛化能力;训练步数:对网络泛化能力具有很大的影响,网络训练步数越多,网络结构越复杂,泛化能力往往将变得很差。

结构自适应神经网络模型的基本思想为:首先,构造训练样本集和测试样本集,在给定神经网络模型初始外部结构参数的情况下,利用神经网络的 BP 算法对训练样本集进行学习,获取模型的内部连接权值参数。再利用测试样本集,对学习模型进行测试,并计算识别误差,形成遗传算法的适应度函数;然后运用遗传算法的学习机制,自动调节神经网络模型的外部结构参数,在新的外部结构参数下,应用神经网络 BP 算法得到模型新的内部连接权值参数,按同样方法计算识别误差和适应度值,再进行下一步调整,直到达到遗传算法停止条件;最后输出具有最优泛化能力的神经网络模型。整个学习过程均自动完成。

4 实例验证

为了验证本文方法的有效性,对 4 类损伤的 14 幅孔探图像,分别旋转 $0^\circ, 45^\circ, 90^\circ, 135^\circ, 180^\circ, 225^\circ, 270^\circ$ 及 315° 后,一共得到包含 4 类损伤的 $14 \times 8 = 112$ 张图像。每张图像提取出角二阶矩、对比度、相关性、方差、逆差矩的均值和方差共 10 个特征参数组成一个 10 维的样本。用其中的 42 个样本(由旋转 $0^\circ, 45^\circ, 90^\circ$ 得到的图像获取)作为神经网络

的训练样本;42个样本(由旋转 135°、180°、225°得到的图像 315°得到的图像获取)作为神经网络的测试样本 2。表 1 为获取)作为神经网络的测试样本 1;28个样本(由旋转 270° 本文提取出的 14幅孔探图像的纹理特征。

表 1 纹理特征参数(原始图像)

Table 1 Texture feature parameters (original images)

编号	角二阶矩		对比度		相关性		方差		逆差矩		损伤类型
	均值	方差	均值	方差	均值	方差	均值	方差	均值	方差	
1	0.133 7	0.006 4	0.146 1	0.048 2	0.984 1	0.005 2	1.092 8	0.039 4	0.948 4	0.014 9	1
2	0.147 8	0.007 3	0.142 9	0.047 8	0.981 9	0.006 0	1.060 8	0.041 0	0.945 3	0.016 0	1
3	0.065 4	0.002 5	0.094 8	0.019 7	0.996 8	0.000 6	1.295 7	0.024 3	0.952 6	0.009 7	2
4	0.067 9	0.002 6	0.160 1	0.031 8	0.995 0	0.000 9	1.347 4	0.027 9	0.927 4	0.012 5	2
5	0.067 4	0.002 3	0.107 5	0.021 0	0.996 4	0.000 7	1.298 2	0.023 3	0.948 4	0.009 4	2
6	0.067 0	0.003 0	0.138 5	0.038 0	0.994 1	0.001 6	1.304 3	0.031 0	0.940 7	0.012 4	2
7	0.098 1	0.003 5	0.111 5	0.023 0	0.995 1	0.000 9	1.201 9	0.025 2	0.946 9	0.010 4	3
8	0.126 7	0.011 5	0.242 5	0.054 3	0.952 4	0.010 6	1.102 3	0.041 4	0.884 9	0.023 9	3
9	0.077 8	0.006 4	0.179 1	0.043 2	0.987 5	0.003 0	1.259 6	0.041 3	0.917 8	0.019 6	3
10	0.105 0	0.003 1	0.078 0	0.016 2	0.994 0	0.001 2	1.135 0	0.021 8	0.961 0	0.008 0	4
11	0.065 9	0.004 1	0.194 5	0.035 0	0.992 8	0.001 6	1.311 5	0.030 2	0.907 0	0.015 8	4
12	0.064 1	0.002 4	0.085 0	0.020 9	0.997 7	0.000 5	1.292 9	0.027 6	0.957 6	0.010 4	4
13	0.068 3	0.003 0	0.102 4	0.023 9	0.995 8	0.000 9	1.277 8	0.028 4	0.950 5	0.011 0	4
14	0.084 2	0.002 4	0.082 4	0.018 3	0.996 1	0.000 8	1.206 2	0.022 6	0.960 1	0.008 3	4

注:1—叶尖卷边;2—腐蚀;3—裂纹;4—撕裂。

本文在结构自适应神经网络模型中,用训练样本集对神经网络进行训练,再用测试样本集 1对神经网络进行测试,根据测试结果,构造遗传算法的适应度函数,通过遗传算法优化后,得到最优的网络结构参数,表 2为优化后得到的各子网络结构参数。运用表 2得到的最优神经网络模型分别对训练样本、测试样本集 1和测试样本集 2进行测试,结果如表 3所示。其中测试样本集 1的

作用是与遗传算法相结合,来优化网络结构;测试样本集 2不参与建模。从测试结果表中可以看出,经过优化后的神经网络对未知孔探图像损伤类型的识别率能高达 82%左右。由此可见,结构自适应神经网络模型对于孔探图像的损伤识别非常有效。显然,如果再结合颜色和形状等其他参数进行综合识别,其识别精度将更高。

表 2 优化后的子网络结构参数

Table 2 Structure parameters of optimized sub-NNs

子网络	优化后的各子网络参数				
	输入节点数	隐层节点数	最大训练步数	网络训练精度	初始权值随机种子
子网络 1	10	28	36	0.001	0
子网络 2	10	28	82	0.001	220
子网络 3	10	5	64	0.001	0
子网络 4	10	19	18	0.001	220

表 3 测试结果

Table 3 Test results

样本集	采样个数	正确分类数	识别率 (%)
训练样本集	42	41	97.619
测试样本集 1	42	39	92.857
测试样本集 2	28	23	82.142

5 结 论

本文针对目前航空公司孔探检测的缺陷,提出了基于孔探图像纹理特征的航空发动机内部损伤识别方法。本文根据基于内容的图像检索思想,详细研究了基于纹理特征的损伤识别的集成神经网络模型。针对神经网络

的结构设计困难问题,采用结构自适应神经网络算法,运用遗传算法实现了网络模型结构参数的自适应选取。经过对真实的发动机孔探图像进行分析,充分验证了损伤识别方法的有效性。本文的研究对于及时有效地对外场航空发动机损伤评估和适时地实现发动机的视情维修具有重要意义。

参考文献

- [1] 顾海涛. 工业视频内窥镜在民航维修中的应用 [J]. 航空维修与工程, 2003 (6): 56-57.
GU H T. Industrial videoprobe s application in chinese civil aviation maintenance [J]. Aviation Maintenance & Engineering, 2003 (6): 56-57.
- [2] CHEN G. 3D measurement and stereo reconstruction for aero-engine interior damage [J]. Chinese Journal of Aeronautics, 2004, 17 (3): 149-151.
- [3] 于辉. 发动机故障诊断技术及基于图像信息的故障诊断 [D]. 南京: 南京航空航天大学, 2002.
YU H. Engine fault diagnosis technology and fault diagnosis based on image information [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2002.
- [4] MULLER H, MULLER W. Performance evaluation in context-based image retrieval: Overview and proposals [J]. Pattern Recognition Letters, 2001, (22): 593-601.
- [5] YONG R. Image retrieval: Current techniques, promising directions and open issue [J]. Journal of visual Communication and Image Representation, 1999, 10 (3): 39-62.
- [6] KANKANHALLIM S. Cluster-based color matching for image retrieval [J]. Pattern Recognition Letters, 2001, 22: 447-455.
- [7] 徐建华. 图像处理与分析 [M]. 北京: 科学出版社, 1992: 139-152.
XU J H. Disposal and analysis of image [M]. Beijing: Science Press, 1992: 139-152.
- [8] 陈果. 一种实现结构风险最小化思想的结构自适应神经网络模型 [J]. 仪器仪表学报, 2007, 28 (10): 1874-1879.
CHEN G. Structure self-adaptive neural network model realizing structural risk minimization principle [J]. Chinese Journal of Scientific Instrument, 2007, 28 (10): 1874-1879.

作者简介



陈果, 1994年、1997年、2000年于西南交通大学分别获得学士、硕士和博士学位, 现为南京航空航天大学教授、博士生导师, 主要研究方向为航空发动机状态监测与故障诊断、智能诊断与专家系统、机器学习与知识获取、图像处理及模式识别、非线性转子动力学等。

地址: 南京航空航天大学民航学院, 210016

电话: 025-84891850; E-mail: cgzyx@263.net

Chen Guo obtained bachelor, master and doctor degrees all from Southwest Jiaotong University in 1994, 1997 and 2000, respectively. He is a professor and supervisor for PhD candidate in Nanjing University of Aeronautics and Astronautics now. His main research fields include aero-engine condition monitoring and fault diagnosis, intelligent diagnosis and expert system, machine learning and knowledge acquisition, image processing and pattern recognition, nonlinear rotor dynamics and etc.

Address: College of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, Jiangsu, China

Tel: +86-25-84891850; E-mail: cgzyx@263.net



汤洋, 2003年于中国民航大学获得学士学位, 现为南京航空航天大学硕士研究生, 主要研究方向为航空发动机状态监测与故障诊断、智能诊断与专家系统、图像处理及模式识别等。

地址: 南京航空航天大学民航学院, 210016

电话: 025-84891850; E-mail: coffeetune@tom.com

Tang Yang obtained bachelor degree from Civil Aviation University of China in 2003. He is a master student in Nanjing University of Aeronautics and Astronautics now. His main research fields include aero-engine condition monitoring and fault diagnosis, intelligent diagnosis and expert system, image processing and pattern recognition and etc.

Address: College of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, Jiangsu, China

Tel: +86-25-84891850; E-mail: coffeetune@tom.com