

基于深度信念网络的航空发动机气路故障诊断技术研究

林嘉琦,徐建国,刘星怡

(南京航空航天大学 能源与动力学院,江苏 南京 210016)

摘要:针对传统的航空发动机故障诊断方法正确率较低,并且对异常数据不敏感的问题,将智能诊断算法引入航空发动机气路故障诊断领域。以涡轴发动机为例,分析了常见气路部件故障类型的成因和表现,并在 Tensorflow 上建立基于深度信念网络的故障诊断模型。与传统的故障诊断方法相比,具有更高的故障诊断正确率。

关键词:航空发动机;气路部件;深度信念网络;故障诊断

中图分类号:V231 **文献标志码:**B **文章编号:**1671-5276(2019)05-0179-04

Research on Fault Diagnosis Technology of Aeroengine Based on Deep Belief Network

LIN Jiaqi, XU Jianguo, LIU Xingyi

(College of Energy and Power, Nanjing University of Aeronautics and Astronautics, Nanjing 210001, China)

Abstract: Because low accuracy and insensitivity to abnormal data exist in the traditional method of fault diagnosis, the intelligent diagnosis algorithm is introduced into the fault diagnosis field of aero-engine gas circuit. Taking the turboshaft for example, the causes and manifestations of common types of gas circuit component faults are analyzed, and a fault diagnosis model based on deep belief network is established on Tensorflow. Compared with the traditional fault diagnosis method, it has a higher fault diagnosis accuracy rate.

Keywords: aero-engine; gas circuit component; deep belief network; fault diagnosis

0 引言

航空发动机是飞机的“心脏”,而发动机故障在飞行故障中又占据着极大的比例,因此解决发动机故障是保证飞行安全的当务之急^[1]。在传统故障诊断方法中,维修人员需耗费大量时间寻找故障的原因。除此之外,有些隐藏的问题光靠人力很难去解决或是被发现,有时这些问题就会酿成不可挽回的惨剧^[2]。因此,智能故障诊断方法对航空发动机健康监测和视情维修有着重要的意义。

在基于神经网络的故障诊断技术方面,前人已经有了一定的研究成果。张鹏采用卡尔曼滤波算法与融合故障神经网络诊断技术进行对比,验证了融合故障神经网络较单一故障诊断系统有更好的故障诊断效果^[3]。刘永建针对民航发动机的典型气路故障,在 BP 网络的基础上改进该神经网络并进行诊断^[4],取得了更好的故障诊断效果。然而,基于浅层神经网络算法的故障诊断技术正确率较低。在训练时间方面,针对一对一的或是多对一的神经网络训练时间较短,但是在多输入、多输出的故障分类时,训练时间较长。

为了解决上述问题,需要引入深度神经网络算法来进行航空发动机故障诊断。深度信念网络(deep belief network, DBN)是 Hinton^[5]于 2006 年提出的,此算法训练时

间短,并且有较好的效果。

1 航空发动机气路故障

涡轴发动机在工作时往往会发生气路故障,并且根据维修人员和国内外大修记录表明,气路故障是航空发动机中发生概率较高的故障类型。气路故障根据性能退化的严重程度,可以分为 2 种,称为气路性能蜕化和部件故障。

本文研究了 5 种典型的涡轴发动机故障模式,包括压气机效率蜕化、燃烧室效率蜕化、燃烧室压力蜕化、燃气涡轮效率蜕化和动力涡轮效率蜕化。在 Simulink 中搭建涡轴发动机模型进行故障模型模拟仿真,针对不同部件性能蜕化选择范围 $[0, 0.04]$,选择蜕化步长为 0.0004,在上述范围内逐渐降低模型的性能值,最后得到不同性能下的涡轴发动机工作参数。将发动机发生故障的阈值设定为 0.01,即蜕化性能大于阈值则认为发生故障,小于阈值则认为气路部件正常性能退化。得到压气机效率蜕化数据 75 组,燃烧室效率蜕化数据 75 组、燃烧室压力蜕化数据 75 组,燃气涡轮效率蜕化数据 75 组、动力涡轮效率蜕化数据 75 组和正常工作状态 125 组,总共 500 组数据作为故障模型的训练及测试数据。数据在训练及测试前均需要进行归一化处理。

2 故障诊断模型搭建

2.1 深度信念网络介绍

深度信念网络是由多个受限玻尔兹曼机层来组成的,在受限玻尔兹曼机的基础之上增添输入、输出层共同建立了深度信念网络。图 1 为典型的深度信念网络模型结构图。

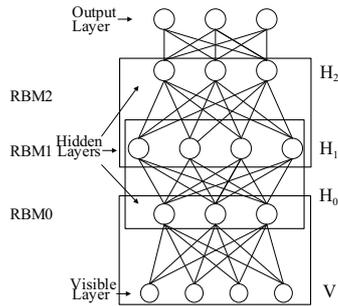


图 1 深度信念网络结构图

由图 1 可见,输入层 V 和隐含层 H_0 共同组成了第 1 个受限玻尔兹曼机层 RBM0。与之相类似,隐含层 H_0 和 H_1 共同组成了 RBM1,隐含层 H_1 和 H_2 共同组成了 RBM2,最后 H_2 与输出层之间根据实际需求可以设置为 BP 层或是 softmax 层。其中受限玻尔兹曼机由多层神经元组成,这些神经元分为两大类:一类称为可见层神经元;另一类称为隐含层神经元。一般说来,可见层神经元主要用于输入数据,而隐含层神经元主要用于特征提取,故将隐含层神经元称作特征提取器。

DBN 采用的训练方法是 Bengio 在 2006 年提出的半监督学习贪婪逐层训练方法^[6],这种训练方法训练时间短,且训练效果较好。

2.2 故障诊断模型构建

对于涡轴发动机典型气路故障进行分析,选取了比较有典型性的参数作为故障诊断网络的特征参数。主要有:压气机出口温度 (T_3)、出口压力 (P_3)、燃烧室出口压力 (P_4)、燃气涡轮出口温度 (T_{42})、出口压力 (P_{42})、动力涡轮出口温度 (T_{45})、出口压力 (P_{45})、负载大小 (P_w)、燃油量 (W_f) 这 9 个参数作为故障诊断数据输入参数。5 种故障模型及正常工作状态共 6 种工作状态分别对应标签如表 1 所示。因此,基于深度信念网络的故障诊断模型输入节点为 9 个,输出节点为 6 个。

表 1 发动机气路部件状态对应输出标签

发动机气路部件工作状态	输出结果对应标签
正常	[1,0,0,0,0,0]
压气机效率蜕化	[0,1,0,0,0,0]
燃烧室效率蜕化	[0,0,1,0,0,0]
燃烧室压力蜕化	[0,0,0,1,0,0]
燃气涡轮效率蜕化	[0,0,0,0,1,0]
动力涡轮效率蜕化	[0,0,0,0,0,1]

根据上述的有关航空发动机故障诊断和深度信念网络理论的叙述,基于深度学习的航空发动机故障诊断主要工作步骤如下所示:

1) 利用涡轴发动机故障的数据,并将数据分为训练组和测试组。

2) 模型的第一层为输入层,该层对应的是故障时观测到的数据输入。中间层为隐含层,其结构为受限玻尔兹曼机,隐含层的节点可以参考上述 BP 神经网络的隐藏层节点设置经验,也可以根据现在的深度神经网络结构来设置隐含层节点个数。最后一层为 softmax 层,节点数为 6,用来对应故障的标签。

3) 采用对比散度算法对模型进行训练。首先是从模型的输入层到隐含层底层的无监督学习,再根据训练数据标签和 max 层进行故障分类,再在 2) 的基础上从最高层往最低层逐步向后微调参数,完成 DBN 模型的整个训练过程。

4) 将测试数据输入 3) 中模型,由输出的概率值来判断出分类的结果。

3 仿真结果及分析

实际发动机参数在测量过程中一般受诸多因素的干扰,同时模型仿真不能精确地反映航空发动机的工作情况,为了更加接近真实的发动机工作情况,在原始数据中加入噪声来模拟真实发动机的工作情况。如下所示:

$$D_n = D + k \text{normairand}(m, n) \quad (1)$$

式中: D_n 为加入噪声后的参数, D 为未加入噪声前的参数, k 为噪声水平, $k=0.02$; $\text{normairand}(m, n)$ 为服从正态分布的随机数。其中随机的均值 (m) 和标准差 (n) 分别设置为 0 和 0.01。

3.1 故障诊断性能对比

为了验证深度信念网络在故障诊断方面的精度,在此选取反向传播神经网络 (back propagation, BP) 进行发动机故障诊断效果的比较研究。基于 BP 神经网络的故障诊断模型搭建采用的是 Simulink 中的神经网络工具箱,该工具箱中包含了各种经典浅层神经网络算法的实现^[7]。基于 BP 神经网络的故障诊断模型共 3 层,输入节点共 9 个,输出节点共 6 个,隐含层节点设置为 10 个。模型的训练方法采用的是 Levenberg-Marquardt 训练算法,模型的学习率设置为 0.01,训练时的收敛条件设定为 0.000 001,最大训练次数为 1000 次。

3.2 不同训练样本比例影响分析

由于在设定测试和训练样本的比例上没有明确的规定,因此在仿真过程中对这两者的比例对训练及测试误差的影响进行了研究分析。对测试样本占总样本数的 40%、60%、80% 不同情况进行了仿真。

深度神经网络中的一些框架参数,例如 k 近邻算法中的 k 值、聚类算法中类的个数等被称为是超参数^[8]。深度信念网络中的超参数包括了隐含层层数、隐含层节点数、预训练阶段及反向微调阶段的学习率等参数。在此探究不同训练样本比例对故障诊断模型性能的影响,因此先要

把其他超参数的值设定下来。在此先设定隐含层层数为3层,各隐含层节点数为10个,学习率为0.01,训练批次为5,训练次数为5000次。表2为不同训练比例的两种算法故障诊断正确率的对比。

表2 两种算法在不同训练样本比例下

采用算法	正确率对比			单位: %
	不同训练样本比例			
	40%	60%	80%	
BP	84.48	89.76	90.09	
DBN	87.87	97.54	98.01	

由以上结果可以看出,在3种不同的训练比例下,基于深度信念网络的故障诊断模型的正确率较基于递归神经网络的相比正确率较高。同时可以看出,当训练样本占总样本比例为80%时,故障诊断的正确率较高,因此在后续的研究工作中,可以将模型的训练样本比例定为80%。

3.3 不同隐含层数影响分析

深度神经网络一般指的是层数 ≥ 4 层的神经网络,就目前来看,还没有研究对网络的层数设定有明确的规定。因此需要对模型隐含层的层数进行研究分析,选定较好的隐含层层数。

根据深度神经网络的定义,在此设定神经网络层数隐含层为2层、3层、4层和5层来探究隐含层对模型性能的影响(图2,表3)。为了减少节点数对对比仿真的影响,将隐含层节点数均设置为10个。

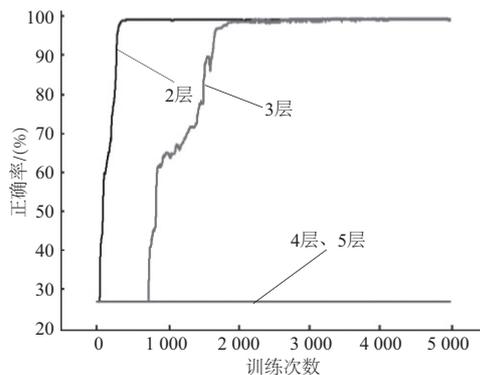


图2 不同隐含层数训练情况对比

表3 故障诊断模型测试结果 单位: %

隐含层数	测试集正确率
2	98.5
3	98.0
4	19.0
5	19.0

从图2和表3可知,模型的隐含层分别设置为2层和3层时,在训练次数达到2000次左右时正确率均能接近100%,且此时的测试集正确率均在98%左右。而隐含层 > 3 层时,模型在训练次数达到5000次后的训练误差仍然较大,并且测试集的正确率也较低。

由上述结果可以知道,深度信念网络的模型隐含层越多,达到较好训练效果所需要的次数也相应增加。在考虑时间成本和测试集正确率的因素下,可以将模型的隐含层数设定为2层,此时模型需要的训练次数较少,并且模型最后的正确率也较高。

3.4 不同隐含层节点数影响分析

深度信念网络的隐含层节点数设置至今没有确定的规则,在此可以根据BP算法设置隐含层的节点数。由于本模型的输入特征较少,可以采用增广型方法来设置隐含层节点数。这种选取方法使隐含层节点数增广,能够较好地反映较少输入节点时的特征^[9]。增广方法根据节点数组合不同,可以分为BP经验公式组合、恒值型组合、升值型组合和降值型组合。

表4 隐含层节点数不同组合

组合名称	第1层	第2层	总节点数
BP经验公式	8	7	15
恒值型	15	15	30
升值型	10	20	30
降值型	20	10	30

模型的超参数,如学习率、训练批次保持不变。不同隐含层节点数组合的训练结果和模型的测试集结果如图3、表5所示。

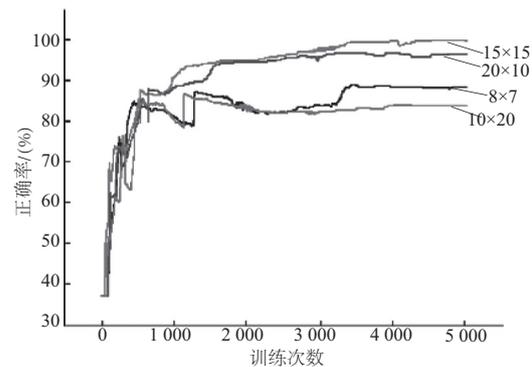


图3 不同节点数组合训练情况对比

由图3可知,在节点数设为15 \times 15组合时模型的训练结果正确率最高,20 \times 10组合的正确率其次,训练结果性能较差的是10 \times 20组合和8 \times 7组合。

当节点组合为15 \times 15时,模型的正确率在训练次数达到2000次左右能接近100%,因此可以选择模型的隐含层节点数组合为15 \times 15。

表5 故障诊断模型测试结果 单位: %

隐含层节点组合	测试集正确率
8 \times 7	61
15 \times 15	99
10 \times 20	81
20 \times 10	98

由图3、表5可以看出模型的隐含层组合为15 \times 15时

的测试集正确率最高,达到了 99%。相较于其性能较差的是 20×10 组合,而 10×20 组合和 8×7 组合的模型正确率都较差,低于 90%。综上所述,隐含层组合应设为 15×15 组合。

3.5 抗噪声能力分析

在发动机实际试车工程中,由于工作环境的影响及传感器的偏差等问题,测试数据往往不十分准确。因此,需要故障诊断模型有较好的抗噪声性能。在此结合式(1),针对 BP 神经网络和 DBN 神经网络,对故障诊断数据添加不同噪声水平,来探究其模型的正确率受其影响的程度。分别对模型添加不同水平的噪声 ($k = 0.02, 0.04, 0.06, 0.08, 0.10$),在模型训练集占总数据 80% 的情况下,测试不同噪声对训练结果的影响(表 6)。

表 6 不同噪声水平下 BP 和 DBN 模型影响分析 单位: %

算法	不同噪声水平的模型正确率				
	0.02	0.04	0.06	0.08	0.10
BP	90	89.5	87.6	85.1	81.4
DBN	99	98.7	97.5	96.1	94.7

由表 6 可知,模型的正确率随着噪声水平的提高而下降。但是总体上来说,DBN 模型的诊断正确率受噪声水平的影响较小。同时在较大的噪声下, $k = 0.10$ 时,模型的诊断正确率依然在 90% 以上。因此,基于 DBN 的故障诊断模型的抗噪声能力优于基于 BP 的故障诊断模型。

4 结语

本文以涡轴发动机为对象,通过 Simulink 中的工具箱

对气路部件蜕化模型进行仿真,得到了故障诊断的数据作为后续故障诊断模型的训练测试集。进而采用递归神经网络和深度信念神经网络来建立故障诊断模型,并针对不同的训练集比例进行仿真,选取了较好的训练集比例。继而比较了基于递归神经网络和深度信念神经网络的抗噪声能力,发现基于深度信念神经网络的抗噪声能力较强,受噪声影响较小,同时在噪声较高的水平下还能保持较高的故障诊断正确率,这说明了基于深度神经网络在故障诊断领域中的良好应用前景。

参考文献:

- [1] 胡严思. 基于 FTA 和 BAM 神经网络的飞机故障诊断系统研究[D]. 长沙: 湖南大学, 2012.
- [2] 范昕宇. 航空发动机传感器神经网络故障诊断及滑膜容错控制研究[D]. 南京: 南京航空航天大学, 2015.
- [3] 张鹏. 基于卡尔曼滤波的航空发动机故障诊断技术研究[D]. 南京: 南京航空航天大学, 2009.
- [4] 刘永建. 基于改进神经网络的民机发动机故障诊断与性能预测研究[D]. 南京: 南京航空航天大学, 2012.
- [5] Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [6] Bengio Y, Lamblin P, Popovici D, et al. Greedy layer-wise training of deep networks[J]. Advances in Neural Information Processing Systems, 2007, 19: 153.
- [7] 彭军, 郭晨阳. 基于深度学习的航空发动机部件故障诊断[J]. 系统仿真技术, 2018, 14(1): 20-24.
- [8] 王秀美. 深度学习在回归预测的研究及应用[D]. 泰安: 山东农业大学, 2017.
- [9] 胡昭华, 宋耀良. 基于 Autoencoder 网络的数据降维和重构[J]. 电子与信息学报, 2009, 31(5): 1189-1192.

收稿日期:2018-05-15

(上接第 164 页)

表 1 织带检测实验数据

检测类型	精度/mm	误检率/(%)	漏检率/(%)
宽度测量	1	—	—
边缘毛刺	1	1.12	0.83
表面毛刺	2	2.72	1.93
白点	1	1.25	0.72

5 结语

所研发的基于 C# 机器视觉的织带检测系统,先控制滚轮精确传送织带,然后利用工业 CCD 相机实时采集图像传送到上位机中,利用图像处理技术完成织带的视觉检测;实现了运动控制、图像采集与显示及图像处理等功能。采用标准的 PC 架构,方便今后硬件升级。目前,检测速度为 0.3 m/s,在某企业的实际生产中,检测精度、效率、可靠性均较好,满足在线检测的要求。

参考文献:

- [1] 李文羽,程隆棣. 基于机器视觉和图像处理的织物疵点检测研究新进展[J]. 纺织学报,2014,35(3):158-164.
- [2] 李冠志. 基于机器视觉的织物瑕疵实时自动检测平台研究[D]. 上海:东华大学,2013.
- [3] 杨少荣,吴迪靖,段德山. 机器视觉算法与应用[M]. 北京:清华大学出版社,2008:2-5.
- [4] 蔡亚. 计算机视觉技术及 LabVIEW 在织物疵点检测中的应用[D]. 上海:东华大学,2008.
- [5] 徐铭倩. 织物疵点小波检测算法研究与 DSP 实现[D]. 常州:常州大学,2012.
- [6] 张莹莹. 织物疵点检测算法研究及其 DM3730 平台实现[D]. 北京:北京服装学院,2014.
- [7] 李景. 速度_张力型三电机协调同步控制平台研制[J]. 微特电机,2017,45(9):5-11.
- [8] 崔明. 基于机器视觉的汽车安全带表面缺陷检测算法研究[D]. 徐州:中国矿业大学,2016.
- [9] 章为川. 基于各向异性高斯核的图像边缘和角点检测[D]. 西安:西安电子科技大学,2013.

收稿日期:2018-06-01