

基于图像融合的燃气轮机故障诊断研究

程卓¹, 曹云鹏², 冯伟兴¹

(1. 哈尔滨工程大学 智能科学与工程系, 哈尔滨 150001;

2. 哈尔滨工程大学, 能源与动力学院, 哈尔滨 150001)

• Research on gas turbine fault diagnosis based on image fusion

ZHENG Zhuo¹, CAO Yunpeng², Feng Weixing¹

- (1. Intelligent science and engineering Department, Harbin Engineering University, Harbin 150001, China;
- 2. College of Power and Energy Engineering, Harbin Engineering University, 150001, Harbin)

Abstract: It is an important research method for fault diagnosis of heavy gas turbine to obtain gas turbine running image by using hole probe and judge the health state of heavy gas turbine by image fault diagnosis. In order to diagnose the operating faults of gas turbine and identify the faults of gas turbine compressor and turbine accurately, a fusion fault diagnosis method of gas turbine based on image is proposed. The running state of the gas turbine is recorded by the hole probe, and the running picture of the gas turbine is obtained. They were input into ResNet and GoogleNet networks for training, and the models with the best diagnostic accuracy were saved respectively to obtain their own fault diagnosis results. The D-S theoretical criterion was used to realize the decision level fusion of the results of the two models. The results show that the image fusion fault diagnosis algorithm can accurately diagnose the fault of gas turbine, with a diagnosis rate of more than 95% and a false alarm rate of less than 1%.

摘要: 利用孔探仪获得燃气轮机的运行图像, 通过图像故障诊断判断重型燃气轮机的健康状态, 是重型燃气轮机故障诊断的一种重要研究方法。为诊断出燃气轮机的运行故障, 并针对燃气轮机压气机与透平的故障进行准确识别, 提出了基于图像的燃气轮机的融合故障诊断的方法。利用孔探仪记录燃气轮机运行状态, 获取燃气轮机运行的图片。分别输入至 ResNet 和 GoogleNet 网络中进行训练, 分别保存诊断精度最好的模型得到各自的故障诊断结果, 再利用 D-S 理论判据实现对两种模型结果的决策层融合。结果表明, 图像融合故障诊断算法可以准确的诊断出燃气轮机的故障, 能得到 95% 以上的诊断率, 不到 1% 的虚警率。

关键词: 燃气轮机; 故障诊断; 决策融合

Key words: gas turbine; fault diagnosis; decision fusion

中图分类号: TK4

文献标识码: A

0 概述

燃气轮机是一个复杂的非线性系统, 它由数以万计的部件构成, 每一个部件都

会对燃气轮机的工作性能产生影响。由于燃气轮机体积小、质量轻等优点, 目前广泛应用于各种分布式能源系统中^[1]。由于燃气轮机长期处于高温、高压以及各种不同

收稿日期: 2023-7-29

基金项目: 船舶动力基础科研项目 (KY10300210082)

作者简介: 程卓 (1998), 男, 硕士生, 主要研究方向为故障诊断, E-mail: 1298213882@qq.com;

曹云鹏 (联系人), E-mail: caoyunpeng@hrbeu.edu.cn.

工况的工作条件下，其部件极易发生损坏，一旦发生机械故障，将会对整个能源站产生不菲的经济损失，甚至会发生一些安全事故^[2]。因此，对燃气轮机进行故障预警和诊断具有重大的意义。

随着技术的不断进步，人们采用的诊断方法也在不断更新^[3]。近年来，图像神经网络技术得到快速发展，该方法能准确识别图片的内容^[4]。本文提出了一种基于 ResNet、GoogleNet 模型和 D-S 理论判据的图像故障诊断融合算法，可以实现对燃气轮机的故障诊断，并且大大提高了故障诊断的精度。

1 理论介绍

1.1 ResNet 网络

随着网络深度的增加，网络能获取的信息量随之增加，而且提取的特征更加丰富。但是在残差结构提出之前，根据实验表明，随着网络层不断的加深，模型的准确率起初会不断的提高，达到最大饱和值，然后随着网络深度的继续增加，模型准确率不但不会继续增加，反而会出现大幅度降低现象，即模型训练过程和测试过程的 error 比浅层模型更高。这是由于之前的网络模型随着网络层不断加深会造成梯度爆炸和梯度消失的问题。残差网络是一种非常有效的缓解梯度消失问题网络，极大的提高了可以有效训练的网络的深度^[5]。

BasicBlock 模块应用与 ResNet-18、ResNet-34 模型。应用 downsample 的 shortcut 分支，在每个 conv_x 组块中的第一层，此时上一层的输入 out_channel 不等于此层所需要的 in_channel，因此通过 downsample 进行维度调整。虚线 shortcut 分支，即在 conv_x 组块中经过第一层的 downsample 调整 in_channel = out_channel，此组块 conv_x 中的后续层不再需要调整 channel_size，因此可以直接恒等映射 X(即 input)^[6]。




图 1.1 Residual 结构

ResNet-layer 中所有模型的大致结构都基本相似，下表给出了 ResNet-18 的模型的网络参数。

表 2.1 ResNet-18 网络参数

layer name	output size	18-layer
conv1	112×112	
conv2_x	56×56	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$
conv3_x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$
conv4_x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$
conv5_x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$
	1×1	
FLOPs		1.8×10^9

本次实验使用 ResNet18 实现图像分类，模型使用 pytorch 集成的模型。ResNet 残差网络提出了一种残差模块，通过堆叠残差模块可以构建任意深度的神经网络，而不会出现退化现象^[7]。ResNet 残差网络提出了批归一化方法来对抗梯度消失，该方法降低了网络训练过程对于权重初始化的依赖

1.2 GoogleNet

在 2014 年的 ImageNet 图像分类竞赛中，GoogleNet 取得了第一名的成绩，其模型参数参数但只有 AlexNet 的十二分之一。GoogleNet 的成功主要得益于 Inception 模块，整个 GoogLeNet 的主体架构可以看成多个 Inception 模块堆叠而成。

Inception 块里有 4 条并行的线路。前 3 条线路使用窗口大小分别是 1×1 、 3×3 和 5×5 的卷积层来抽取不同空间尺寸下的信息，其中中间 2 个线路会对输入先做 1×1 卷积来减少输入通道数，以降低模型复杂度。 1×1 卷积的主要目的是为了减少维度，还用于修正线性激活（ReLU）。比如，上一层的输出为 $100 \times 100 \times 128$ ，经过具有 256 个通道的 5×5 卷积层之后（ $\text{stride}=1$ ， $\text{pad}=2$ ），输出数据为 $100 \times 100 \times 256$ ，其中，卷积层的参数为 $128 \times 5 \times 5 \times 256 = 819200$ 。而假如上一层输出先经过具有 32 个通道的 1×1 卷积层，再经过具有 256 个输出的 5×5 卷积层，那么输出数据仍为 $100 \times 100 \times 256$ ，但卷积参数量已经减少为 $128 \times 1 \times 1 \times 32 + 32 \times 5 \times 5 \times 256 = 204800$ ，大约减少了 4 倍。第 4 条线路则使用 3×3 最大池化层，后接 1×1 卷积层来改变通道数。4 条线路都使用了合适的填充来使输入与输出的高和宽一致。最后我们将每条线路的输出在通道维上连结，并向前进行传输。




图 1.2 Inception 结构

基于 Inception 构建了 GoogLeNet 的网络结构如下图所示（共 22 层）：




图 1.3 GoogleNet 结构

其中 3a、3b、4a、4b、4c、4d、4e、5a 和 5b 是 Inception 结构。为了避免梯度消失，网络额外增加了 2 个辅助的 softmax 用于向前传导梯度（辅助分类器），这两个辅助分类器的输入分别来自 Inception(4a)和 Inception(4d)。辅助分类器的第一层是一个平均池化下采样层，池化核大小为 5×5 ， $\text{stride}=3$ ；第二层是卷积层，卷积核大小为 1×1 ， $\text{stride}=1$ ，卷积核个数是 128；第三层是全连接层，节点个数是 1024；第四层是全连接层，节点个数是 1000（对应分类的类别个数）。在模型训练时的损失函数按照下式：

$$L_{\text{loss}} = L_0 + 0.3 * L_1 + 0.3 * L_2$$

L_0 是最后的分类损失。辅助分类器是将中间某一层的输出用作分类，并按一个较小的权重（0.3）加到最终分类结果中，这样相当于做了模型融合，同时给网络增加了反向传播的梯度信号，也提供了额外的正则化，对于整个网络的训练很有裨益。而在实际测试的时候，这两个额外的 softmax 会被去掉。

原始输入图像为 $224 \times 224 \times 3$ ，且都进行了零均值化的预处理操作。

1.3 D-S 理论判据

D-S 理论判据是对贝叶斯推理方法推广，主要是利用概率论中贝叶斯条件概率来进行的，需要知道先验概率。而 D-S 证据理论不需要知道先验概率，能够很好地表示不确定”，被广泛用来处理不确定数据。适用于：信息融合、专家系统、情报分析、法律案件分析、多属性决策分析。

假定识别框架 Θ 下，两个证据 E_1 和 E_2 相应的基本信任分配函数分别为 m_1 和 m_2 ， A_i 和 B_j ，则 Dempster 合成规则为：

$$m(A) = \begin{cases} \frac{\sum_{A_i \cap B_j = A} m_1(A_i) m_2(B_j)}{1 - K}, & A \neq \phi \\ 0, & A = \phi \end{cases}$$

$$K = \sum_{A_i \cap B_j = \phi} m_1(A_i) m_2(B_j) < 1$$

其中， K 是冲突系数，能够描述出证据

间的冲突大小情况, K 越大表明证据之间的冲突越大。当 $K=1$ 时, Dempster 组合规则无法进行计算。 $1/1-K$ 为正则化因子, 本质上是为了使 $m(A)$ 的总和值为 1。

对于多个证据的合成, 计算思路是一样的。多个 $m_1, m_2, \dots, m_n$ 函数也可以使用正交和的方式进行处理, 产生一个新的 m 函数, 可以表达为 $m_1 \oplus m_2 \oplus \dots \oplus m_n$ 。若 $m_1 \oplus m_2 \oplus \dots \oplus m_n$ 存在, 那么在计算的过程中顺序对结果没有任何影响, 满足交换率和结合率。假定同一识别框架 Θ 下, 存在 n 组证据 $E_1, E_2, \dots, E_n$, $m_1, m_2, \dots, m_n$ 为对应的基本信任分配函数, 焦元分别为 $A_1, A_2, \dots, A_n$, 则 Dempster 合成规则为:

$$m(A) = \begin{cases} \frac{\sum_{\cap A_i = A} \prod_{1 \leq i \leq n} m_i(A_i)}{1-K}, & A \neq \Phi \\ 0, & A = \Phi \end{cases}$$

$$K = \sum_{\cap A_i = \Phi} \prod_{1 \leq i \leq n} m_i(A_i)$$

2 图像故障诊断实验

2.1 燃气轮机融合故障诊断流程

本项目提出了 Google-ResNet 图像信息融合的故障诊断方法, 如图 2.1 所示。




图 2.1 基于图像层面的故障诊断框架

利用孔探针、红外监测仪记录 9FA 重型燃气轮机发生涡轮叶片涂层脱落和健康运行时的图片, 将图片分为训练集、验证集和测试集并分好标签。

在经过人工剔除光线不充足、不均匀等低质量图片后, 再对图像进行旋转和翻

转等操作来扩充图像数据集, 如图 2.2、2.3 所示^[8]。




图 2.2 涡轮叶片涂层脱落图片



图 2.3 旋转翻转后涡轮叶片涂层脱落图片

最终本项目收集了实验台 297 张健康的图片和 111 张脱落的图片放入训练集, 97 张健康的图片和 46 张脱落的图片放入验证集, 将 688 张健康的图片和 312 张脱落的图片放入测试集, 用于进行燃气轮机涡轮叶片涂层脱落的故障诊断。对训练集、验证集和测试集图片, 调整图片输入大小为 224×224 或 128×128 , 并进行归一化。读取训练集的图片对 ResNet 模型和 GoogleNet 模型进行训练, 利用验证集检测模型每轮训练的结果, 保存准确率最高的模型。读取保存的模型并对测试集图片进行检测, 得到分类结果。

对训练集、验证集和测试集图片, 调整图片输入大小为 224×224 或 128×128 , 并进行归一化。输入至 GoogleNet 或 Resnet 网络。使用交叉熵作为损失函数, 模型采用 resnet18 和 Googlenet, 使用预训练模型。优化器选用 Adam。运用训练集和验证集进行训练和验证, 进行 20 或 30 轮训练

后，保存验证集准确率最高的模型。先定义类别，这个类别的顺序和训练时的类别顺序对应。然后对数据进行预处理，处理方法与验证集一样。最后加载模型，读取图片并预测图片类别。

利用图像各种方法得到诊断结果后先对图像的各类故障诊断结果。利用 D-S 证据理论对各类结果的概率进行融合，最终得到各个图像融合后的故障诊断结果。

3 图像融合故障诊断结果

3.1 ResNet 故障诊断结果

采用 resnet18 为主干网络进行故障诊断。训练过程中输入大小被调整为 128×128 。使用 Adam 为梯度下降优化器，使用批归一化作为正则器。同时，学习率为 0.0001，对上述模型训练 20 个周期，批次大小为 16。训练完毕后得到模型对验证集的准确率变化和损失变化，如图 3.1、3.2 所示：




图 3.1 ResNet 故障诊断准确率变化




图 3.2 ResNet 故障诊断损失变化

如图 3.1、图 3.2 所示，随着训练轮次的增多，损失逐渐下降，图像网络分类准确率逐渐上升，最后图像分类准确率上升至 91% 左右，达到分类要求。由此可知，ResNet 残差神经网络模型可以很好的完成

此项目提出的图像分类任务。本次研究利用 resnet 残差神经网络模型，成功地实现了燃气轮机叶片涂层脱落图像分类，测试集的诊断精度达到 95.8%，虚警率为 0，满足技术指标要求。

3.2 GoogleNet 故障诊断结果

采用 GoogleNet 为主干网络进行评估。训练过程中输入大小被调整为 224×224 。使用 Adam 为梯度下降优化器，使用批归一化作为正则器。同时，学习率为 0.0001，对上述模型训练 30 个周期，批次大小为 16。训练完毕后得到模型对验证集的准确率变化和损失变化，如图 3.3、3.4 所示：




图 3.3 GoogleNet 故障诊断准确率变化




图 3.4 GoogleNet 故障诊断损失变化

利用 GoogleNet 模型，将含有脱落和健康的图片测试集输入后可看到此图片分类后结果，健康图片有 682 张诊断为健康，6 张诊断为故障，故障图片有 259 张诊断为故障，53 张诊断为健康，诊断准确率为 94.1%，虚警率为 0.87%，满足技术指标要求。可以看出利用 GoogleNet 残差神经网络分类后的标签是准确的。

3.3 融合故障诊断结果

利用 ResNet 模型和 GoogleNet 模型进行多次实验对比模型准确率，画出多次实

验过程所得的准确率曲线,结果如图 3.5 所示。由下图可得,ResNet 网络故障诊断率的平均值为 92.5%,Googlenet 网络故障诊断率为 93.2%,Googlenet 网络的平均准确率略高于 ResNet,且稳定性更好。




图 3.5 ResNet 模型与 GoogleNet 模型对比结果

输出两个模型对图片分类的概率,比如一个图片 ResNet 模型诊断得到健康的概率为 0.994,脱落的概率为 0.00571;GoogleNet 模型诊断得到健康的概率为 0.987,脱落的概率为 0.0129。利用 D-S 证据理论,对两个模型分类概率进行融合。以这个图片的两个模型分类概率为例。

$$k = m_1(\text{健康}) \cdot m_2(\text{健康}) + m_1(\text{脱落}) \cdot m_2(\text{脱落})$$

$$k = 0.994 \times 0.987 + 0.00571 \times 0.0129 = 0.981$$

$$m_1 \oplus m_2(\{\text{健康}\}) = \frac{1}{K} \sum_{B \cap C = \{\text{健康}\}} m_1(\{\text{健康}\}) \cdot m_2(\{\text{健康}\})$$

$$m_1 \oplus m_2(\{\text{健康}\}) = \frac{1}{0.981} \times 0.994 \times 0.987 = 1.00$$

$$m_1 \oplus m_2(\{\text{脱落}\}) = \frac{1}{K} \sum_{B \cap C = \{\text{脱落}\}} m_1(\{\text{脱落}\}) \cdot m_2(\{\text{脱落}\})$$

$$m_1 \oplus m_2(\{\text{脱落}\}) = \frac{1}{0.981} \times 0.00571 \times 0.0129 = 0.00$$

所以此图片融合诊断结果为健康,诊断结果正确。

最终将两个模型利用 D-S 理论判据得到的决策融合后的结果为健康图片 687 张诊断为健康,1 张诊断为故障,故障图片 264 张诊断为故障,48 张诊断为健康。最终得到结果故障诊断率为 95.1%,虚警率为 0.1%,满足技术指标要求。融合后的故障诊断结果与单独模型的故障诊断结果对比图如图 3.6 所示:




图 3.6 故障诊断结果对比图

由上图可得,决策融合后的准确率略低于 ResNet,略高于 GoogleNet。

4 结论

本文研究了一种基于决策融合的重型燃气轮机图像故障诊断方法。利用 D-S 理论判据结合 ResNet 模型和 GoogleNet 模型构建了重型燃气轮机图像融合故障诊断模型,并通过实验对模型及相应算法进行了验证。

(1) 利用孔探针在重型燃气轮机上记录实际运行中健康与发生涡轮图层脱落故障时的图片,利用旋转、翻转、缩放等操作对图片数据集进行扩充,经过预处理后用于对融合故障诊断算法进行验证。

(2) 利用 D-S 理论判据决策融合后的算法故障诊断准确率为 95.1%,虚警率为 0.1%。

参考文献:

- [1] 赵磊,张永祥,朱丹宸.复杂装备滚动轴承的故障诊断与预测方法研究综述[J].中国测试,2020,46(03):17-25.
- [2] Antoni J, Borghesani P. A statistical methodology for the design of condition indicators [J]. Mechanical Systems and Signal Processing, 2019,114(JAN.1):290-327.
- [3] CAO Y,DONG Y,CAO Y, et al.Two-stream convolutional neural network for non-destructive subsurface defect detection via similarity comparison of lock-in thermography signals[J].NDT&E Int,2020,112:102246.

-
- [4] APPIAH A Y, ZHANG X, AYAWLI B B K, et al. Long short-term memory networks based automatic feature wxtraction for photovoltaic array fault diagnosis[J]. IEEE Access, 2019, 7:30089-30101.
 - [5] CHEN Z, CHEN Y, WU L, et al. Deep residual network based fault detection and diagnosis of photovoltaic arrays using currentvoltage curves and ambient conditions[J]. Energy Convers Manage, 2019, 198:111793.
 - [6] HONG Y Y, PULA R A. Detection and classification of faults in photovoltaic arrays using a 3D convolutional neural network[J]. Energy, 2022, 246:123391.
 - [7] LU X, LIN P, CHENG S, et al. Fault dianosis for photovoltaic array based on convolutional neural network and electrical time series graph[J]. Energy Convers Msnsg, 2019, 196:950-965.
 - [8] 秦桂林. 航空发动机主轴轴承故障诊断方法研究[D]. 北京化工大学, 2016.