

基于扩散连接试样金相照片的非焊合缺陷的自动识别*

胡京徽¹, 谢鹏志^{1,2}, 杨威^{1,2}, 姚罡¹

(1. 中国航空制造技术研究院, 北京 100024;
2. 数字化制造技术航空科技重点实验室, 北京 100024)

[摘要] 介绍了机器学习方法在工业信息化中的应用, 并结合航空制造业中典型装备生产中的自动识别需求提出了机器学习平台的构建方法。该方法包括: 机器学习平台构建的总体方案、自动检测模型的设计及优化、检测模型的训练和经验性试验评估。以典型的整流叶片扩散连接缺陷自动检测场景为例, 完成了缺陷检测识别准确率高达 96% 以上的模型训练, 验证了机器学习平台的可行性和有效性。

关键词: 机器学习; 扩散连接; 缺陷检测; 整流叶片; 自动检测

Automatic Detection of Non-Welding Defects Based on Metallographic Photographs of Diffusion Bonding Samples

HU Jinghui¹, XIE Pengzhi^{1,2}, YANG Wei^{1,2}, YAO Gang¹

(1. AVIC Manufacturing Technology Institute, Beijing 100024, China;
2. Aeronautical Key Laboratory for Digital Manufacturing Technology, Beijing 100024, China)

[ABSTRACT] This paper introduces the application of machine learning methods in industrial informationization, and proposes the construction method of machine learning platform to satisfy the automatic detection requirements in typical equipment production of aviation manufacturing. The method includes: construction of an overall scheme of the machine learning platform, design and optimization of the automatic detection model, training of the detection model and empirical experimental evaluation. This paper takes the automatic detection of diffusion bonding defects of stator vanes as an example, and trains the model with defect detection accuracy which is more than 96%, verifies the feasibility and effectiveness of the machine learning platform.

Keywords: Machine learning; Diffusion bonding; Defects detection; Stator vanes; Automatic detection

DOI:10.16080/j.issn1671-833x.2020.21.080

扩散连接(Diffusion Bonding, DB)是一种广泛运用于现代航空制造领域的先进钣金成形制造技术^[1-2]。扩散连接技术具有成本低、可靠性高、稳定性好等诸多优势, 主要的应用场景有飞机机身壁板、防火墙、航空发动机舱、静/转子叶片等复杂空腔结构的制造。目前, 由于钣金材料表面状态, 扩散连接温度、压力、保压时间等一系列工艺参数的影响, 扩散连接成形的工件会存在一定比例的非焊合缺陷, 工业上通常要求采用无损检测方法对装机件进行检测, 确保工件的质量。早期, 对于尚未建立可行的无损检测方法的应用场合, 需要通过工件加工余量区取样, 进行金相显微观察, 然后根据其

观察结果, 推测工件中是否存在扩散缺陷。这种方法首先抽样检测同一批次的一部分样品, 然后人工判定产品是否存在缺陷。然而, 随着产品检测需求量的日益增加, 一方面, 传统的人工判定方式已经不能满足日常工作的需求; 另一方面, 由于检测人员的工作经验参差不齐, 在长时间检测过程中还可能疲劳误判漏判。如何使用软件代替人工判定使判定标准一致, 减少误判漏判已经成为目前工业界亟待解决的问题。因此, 本文提出了一种可以自动检测扩散连接缺陷的机器学习平台的构建方案, 并将其应用到实际工业场景中。

1 机器学习平台构建总体方案

本文所构建的机器学习平台包括影像存储、模型训

* 基金项目: 航空基金(KH361706145)。

练和检测平台 3 个模块,具体方案流程如图 1 所示。

影像存储模块功能是对原始影像数据收集、整理和存储。影像收集步骤将原始金相影像数据收集到系统中;接着,人工标注步骤提供人工标注原始数据的功能;然后,影像对齐步骤对影像进行对齐操作,使得输入数据符合对齐的标准;最后,将标注好的影像数据分成训练集和测试集两个部分,其中训练集用于检测平台模块训练初始样本数据,测试集用于模型训练模块来评估卷积神经网络。

检测平台模块是系统的底层应用,它的输入是训练集,通过网络提供给模型训练模块基础的训练数据。检测平台内部的一个核心部件是影像采样,它包含特征提取器、图像增强器和图像窗口生成器。通过这些采样预处理步骤可以将训练集中的数据处理成识别所需要的图片窗口。识别平台的另一个核心部件就是 TensorFlow 训练平台, TensorFlow 平台读取窗口图片,通过定义损失函数、优化器以及训练梯度和参数来提供机器学习模型的建模要素。

模型训练模块是算法工程师训练和调优智能化识别算法的主要模块。由于算法训练需要消耗大量的计

算资源,故模型训练模块的底层采用了 GPU 高性能计算服务器作为主要硬件资源,同时通过 CPU 作为辅助计算的备选方案。两类不同架构的硬件资源提供一套模型基础算法接口向上兼容。硬件资源之上是模型的构建和调优部分,该部分接收模型输入数据,使用训练数据来训练深度学习模型,使用测试数据来评估和验证模型的好坏。本文采用深度学习神经网络作检测识别的模型,该模型的重要工作就是对卷积神经网络的层级关系,神经元数量、丢弃层以及池化层等相关参数反复试验调优来得到识别率高的检测模型。同时,模型训练模块还需要接收影像存储模块中的测试集数据,通过测试集中数据来对训练后模型的实际识别效果进行评估。

2 卷积神经网络构建与训练方法

2.1 卷积神经网络的构建

卷积神经网络是机器学习中一种非常常见的网络结构^[3]。近几年,由于高性能计算的快速发展和 GPU 并行计算的应用普及,卷积神经网络在工业级开发场景中发生了巨大的变化^[4]。本文中建立的机器学习模型就是基于开源工业级深度学习框架 TensorFlow^[5]。

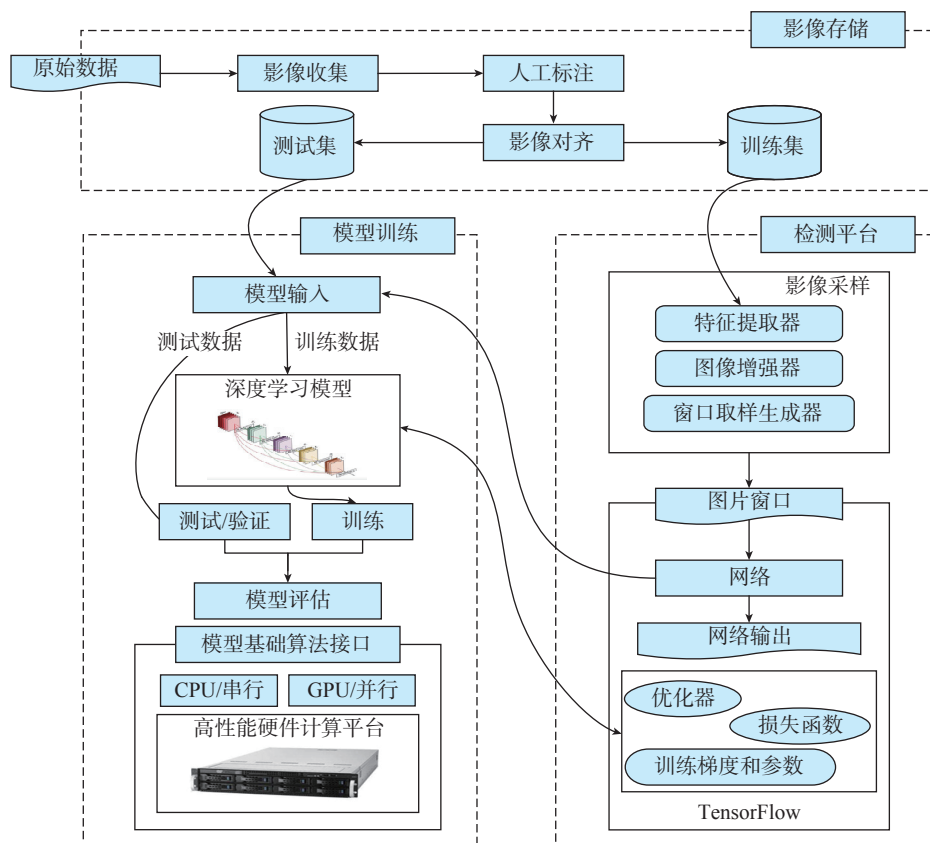


图1 平台构建总体方案图

Fig.1 Overall platform construction architecture

本文中的卷积神经网络主要基于 AlexNet 模型并对网络参数调整然后进行试验,下一步的工作着重结合 VGG 和 ResNet 等网络模型进一步试验,模型具体参数如表 1 所示,模型的输入是分辨率为 256×256 的单通道灰度图像,输入图片经过第 1 个卷积层 conv1 得到 256×256×16 的特征图,其中 conv1 中的卷积运算核维度为 5×5,卷积步长为 1,采用 same 填充方式;接着,特征图通过第一个池化层 pool1, pool1 采用最大池化方式,选取维度 2×2、步长为 2 的核来完成池化操作,得到 128×128×16 的特征图;然后,使用类似的方法经过第 2 个卷积层 conv2 和第 2 个池化层 pool2 得到 64×64×32 的特征图。在完成卷积操作后,特征图会通过一个全连接层 dense 得到 131072 个训练参数;然后,通过一个丢弃层 dropout 来控制参数保留比例,防止模型在训练集上产生过拟合现象^[6];接着,通过两个前向传递层 fc1 和 fc2 将训练参数数量变成 512 和 64;最后,输出参数通过 softmax 分类器得到判定结果。

2.2 机器学习平台的模型训练方法

本文中的模型训练方法流程如图 2 所示,每个步骤的功能如下。(1)输入数据增强:该步骤将输入的图像数据进行扩充,对原始图像进行旋转、缩放、平移以及对称变换等操作,这些操作在获取更多的训练数据的同时可以使得训练后的模型识别时不受几何变换影响。(2)模型参数初始化:在上一个小节中定义的卷积神经网络中包含了大量的权值矩阵和偏置向量参数,这些参数初始化策略有很多种,不同的初始化策略可能会对模型求解过程和参数收敛速度有一定的影响,常见的有标注初始化^[7]、随机正态分布初始策略、Gram-Schmidt 正交化初始策略以及随机正交初始策略^[8],本文采用最常见的随机正态分布初始策略来初始化网络中的权值。(3)获取下一批数据:使用全部训练集数据来训练会使得模型计算量过大而增加训练时间。试验证明采用小批量加入随机噪音的训练方式可以显著提高训练效果^[9]。因此,本文每次在训练集中随机选取一定数量的样本作为同一批次训练数据来训练模型,后文中将批次数量记做 batch_size 值。(4)模型参数优化:该步骤定义了模型的损失函数、优化器、学习率等训练的基本要素,通过反向传播算法^[10]来寻找模型梯度下降的路径,不断改进模型达到对模型参数优化。同时,为了避免过拟合现象,在模型中插入了丢弃层,通过调整丢弃层的保留比例来动态控制需要保留连接边的数量,后文中将保留比例记做 keep_prob 值。(5)评估模型准确率:在每个小批次训练过程中,需要对上一次训练的模型中的好坏进行评估,本文统计每个小批次数据在模型识别准确率,即在新的批次数据中统计模型中识别正确的数量占该

批次总数的百分比。(6)训练终止条件:模型训练过程需要定义算法的终止条件。通常定义终止条件有两种:一种是预先定义算法迭代次数;另一种是预先定义损失值的终止范围,本文中采用前者作为终止条件,后文中将总迭代次数记做 epochs 值。

3 应用案例及试验分析

3.1 试验数据

本文试验数据是某单位检测中心自 2014 年至 2018

表1 卷积神经网络参数
Table 1 Parameters of convolutional neural network

	类型	核	步长	填充	输出维度
input	image	—	—	—	256×256×1
conv1	—	5×5	1	same	256×256×16
pool1	max	2×2	2	same	128×128×16
conv2	—	3×3	1	same	128×128×32
pool2	max	2×2	2	same	64×64×32
dense	—	—	—	—	131072
dropout	—				
fc1	—	—	—	—	512
fc2	—	—	—	—	64
softmax	—				

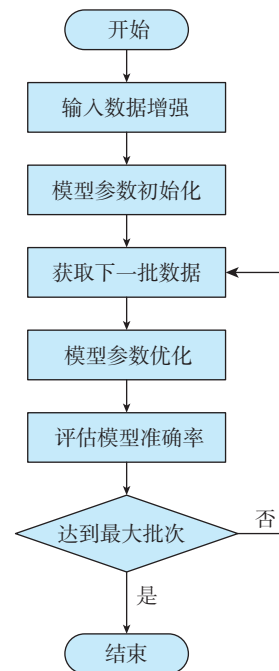


图2 模型训练流程图

Fig.2 Training flow chart of the model

年总共 5 年的检测报告中的影像数据。样本数据是航空发动机中整流叶片检测结果图像,可分为正样本和负样本两类,正样本是检测合格的产品,负样本中出现非焊接缺陷,是检测不合格的产品。试验数据一共包含 46101 条数据,其中 23191 条正样本和 22910 条负样本。图 3 列举了试验数据的部分正负样本,其中,图 3 (a) 为正样本,图 3 (b) 为负样本。

3.2 机器学习平台的试验环境


本文中机器学习平台训练的硬件环境是 Nvidia Tesla V100 16GB 型号计算级显卡,搭载了 48 核心 Intel (R) Xeon (R) Gold 5118 2.30GHz 的 CPU。平台的软件环境是基于 CUDA 10 运行时环境,使用 cuDNN v7.4.2.24 库加速卷积计算过程;在 Python 3.6.5 中编译了 TensorFlow 1.12.0 wheel 安装包作为基础开发框架。

3.3 机器学习平台训练过程分析


机器学习平台训练过程详见 2.2 节,本文为评估机器学习的训练效果一共做了 3 组独立随机试验。每组试验选取的迭代次数 epoch 值为 1400 次,保留比例 keep_prob 值为 0.6,批数量 batch_size 值分别为 200、300 和 400。训练的识别准确率随训练迭代次数变化如图 4 所示。

(1)图 4 中的 3 个子图的横轴表示迭代次数;纵轴表示对应的识别准确率的百分比;蓝色实线为识别准确率为 50% 分位线;红色虚线是准确率为 96% 分位线。可以看出:在模型初始化权值的情况下,识别准确率一般在 50% 左右;随着训练迭代次数的增加,模型的识别准确率不断提高,在 3 次小组试验中都达到了 96% 以上。机器学习平台的训练过程是有效的。

(2)图 4 中的 3 个子图从上至下依次将批数量 batch_size 值设置成了 200、300 和 400。通过对比 3 张子图可以看出,不同 batch_size 值对模型的识别准确率最终收敛效果影响较小,只是识别准确率收敛速度不尽




(a) 正样本




(b) 负样本

图3 正负样本试验数据示例


Fig.3 Example of positive and negative sample data



(a) batch_size=200, keep_prob=0.6



(b) batch_size=300, keep_prob=0.6



(c) batch_size=400, keep_prob=0.6

图4 准确率随训练迭代次数变化

Fig. 4 Accuracy rate as a function of training iterations

相同。由此可见,在进行小批量的训练时, batch_size 值的选取只要在合理的范围内就不会对模型训练过程产生较大的影响,最终都可以得到较优的模型。

通过上述分析可以得知:机器学习平台在训练集的训练效果是合理有效的,通常可以达到 96% 的识别准确率。

3.4 机器学习平台在测试集上识别结果评估

本文将试验数据按照 0.9 比值划分成了训练集和测试集。首先在训练集数据基础上训练好模型,然后在测试集上做预测试验,最好,计算出准确率、正确率、召回率和 F_1 值。相关参数的计算公式为:

$$\text{正确率 } P = \frac{TP}{TP + FP} \quad (1)$$

$$\text{召回率 } R = \frac{TP}{TP + FN} \quad (2)$$

$$F_1 = 2 \times \frac{P \times R}{P + R} \quad (3)$$

式中, TP 表示把正类预测为正类的数量; FP 表示把负类预测为正类的数量; FN 表示把样本中原来正类预测为负类的数量。

本试验分别变化迭代次数 epoch、批数量 batch_size 和保留比例 keep_prob 这 3 个参数。其中, epoch 值选取了 1000、1200 和 1400 3 个数值; batch_size 值选取了 200、300 和 400 3 个数值; keep_prob 值选取了 0.6 和 0.9 这两个数值。本文共完成了 18 组独立随机试验,试验的结果统计如表 2 所示,根据试验结果统计可以看出:

(1) 18 组独立随机试验中的 epoch 数值从 1000、到 1400 变化,平均准确率最低达到 93.8%,最高达到 95.9%,并且随着训练次数的增加平均准确率不断提高。纵观这 18 组试验结果,识别准确率最大值出现在 epoch

表2 测试集各项试验结果统计表
Table 2 Statistics of experimental results in test set

试验参数				评估结果			
试验组数	epoch	batch_size	keep_prob	准确率 /%	正确率 /%	召回率 /%	F_1 值 /%
1	1000	200	0.6	94.0909	91.2069	97.4217	94.2119
2	1000	200	0.9	84.7273	78.3447	95.4420	86.0523
3	1000	300	0.6	96.0714	99.3306	92.6958	95.8986
4	1000	300	0.9	96.6190	96.6330	96.5401	96.5865
5	1000	400	0.6	97.6250	96.4921	98.7860	97.6256
6	1000	400	0.9	93.8000	94.1748	93.2221	93.6960
平均值				93.8223	92.6970	95.6846	94.0118
最大值				97.6250	99.3306	98.7860	97.6256
7	1200	200	0.6	91.8864	90.6768	93.1400	91.8919
8	1200	200	0.9	97.2955	97.4572	97.0534	97.2549
9	1200	300	0.6	92.8095	90.9719	94.9063	92.8975
10	1200	300	0.9	97.1429	97.7129	96.4921	97.0986
11	1200	400	0.6	97.1000	97.2095	96.9145	97.0618
12	1200	400	0.9	95.5000	96.9681	93.8290	95.3728
平均值				95.2890	95.1661	95.3892	95.2629
最大值				97.2955	97.7129	97.0534	97.2549
13	1400	200	0.6	97.6364	96.8722	98.3886	97.6245
14	1400	200	0.9	95.6591	98.9136	92.2192	95.4491
15	1400	300	0.6	95.7381	93.7443	97.9337	95.7932
16	1400	300	0.9	91.7143	88.8739	95.1946	91.9258
17	1400	400	0.6	97.2500	95.8272	98.7355	97.2596
18	1400	400	0.9	97.5750	98.0573	97.0157	97.5337
平均值				95.9288	95.3814	96.5812	95.9310
最大值				97.6364	98.9136	98.7355	97.6245

(下转第97页)

SUN Tianfa. Flexible manufacturing strategy[J]. *Economy and Management*, 2004(7): 11-14.

[5] 严隽琪, 倪炎裕, 马登哲. 基于网络的敏捷制造[J]. *中国机械工程*, 2000(2): 110-113.

YAN Juanqi, NI Yanrong, MA Dengzhe. Internet-based agile manufacturing[J]. *Chinese Journal of Mechanical Engineering*, 2002(2): 110-113.

[6] 蔡元龙, 陈玉宝. 面向敏捷制造的智能制造单元框架结构的研究[J]. *计算机集成制造系统*, 1999, 5(4): 25-28.

CAI Yuanlong, CHEN Yubao. Research of intelligent manufacturing cell structure for agile manufacturing[J]. *Computer Integrated Manufacturing Systems*, 1999, 5(4): 25-28.

[7] 张申生, 曹健, 王英林. 敏捷制造的理论、技术与实践[M]. 上海: 上海交通大学出版社, 2000: 45-56.

ZHANG Shensheng, CAO Jian, WANG Yinglin. The theory technology and practice of agile manufacturing[M]. Shanghai: Shanghai Jiaotong University Press, 2000: 45-56.

[8] 闪四清. ERP 系统原理和实施[M]. 北京: 清华大学出版社有限公司, 2006.

SHAN Siqing. ERP system mechanics and practice[M]. Beijing: Tsinghua University Press, 2016.

[9] 邓永刚. 工业机器人重复定位精度与不确定研究[M]. 天津: 天津大学, 2015.

DENG Yonggang. Industrial robot repositioning accuracy and uncertainty research[M]. Tianjin: Tianjin University, 2015.

通讯作者: 潘登, 硕士, 研究方向为智能制造, E-mail: Palladiapan@gmail.com.

(责编 大漠)

(上接第84页)

为 1400, batch_size 为 200, keep_prob 为 0.6 的第 13 小组试验, 识别准确率高达 97.6%。所以本文中建立的机器学习平台可以出色地完成扩散连接缺陷自动检测任务。

(2) 在 18 组预测试验中, 正确率平均值最低达到了 92.7%, 召回率平均值最低达到了 95.3%, F_1 值平均值最低达到了 94.0%; 正确率最大值达到了 99.3%, 召回率最大值达到了 98.8%, F_1 值最大值达到了 97.6%。所以, 本文中建立的机器学习平台在对大规模扩散连接检测任务中可以高效地提取有缺陷的样本, 优化人工检测流程。

通过在测试集上的对照试验结果分析, 可以得出: 本文设计的自动识别模型的识别准确率已经基本满足减少人工重复工作的需求。本模型在实际应用场景中测试能到达约 1500 张/s 的处理速度, 能够很好地完成非焊合缺陷自动识别任务。

4 结论

本文针对目前扩散连接缺陷检测人工处理效率低和检测人员长期工作容易产生疲劳漏判的现状, 提出了构建对扩散连接缺陷检测的机器学习平台总体设计方案。此外, 还将机器学习平台应用到整流叶片缺陷检测实际工业案例中, 完成了在某单位近 5 年内总计 46101 条的整流叶片检测影像数据集上的评估试验。试验结果证明: 本文所提出的缺陷检测模型对整流叶片非焊合缺陷的识别准确率可以达到 96% 以上, 并且在测试集中也表现出很好的预测效果。

参考文献

[1] 闫亮亮, 童国权, 刘剑超, 等. TA15 四层板结构超塑成形 / 扩散连接技术研究[J]. *航空制造技术*, 2016, 59(19): 88-90, 97.

YAN Liangliang, TONG Guoquan, LIU Jianchao, et al. Research on superplastic forming/diffusion bonding for four-sheet structure of TA15 titanium alloy[J]. *Aeronautical Manufacturing Technology*, 2016, 59(19): 88-90, 97.

[2] 邓武警, 陈玮, 李志强, 等. 扩散连接界面缺陷对 Ti-6Al-4V 合金力学性能的影响[J]. *航空制造技术*, 2017, 60(18): 74-78.

DENG Wujing, CHEN Wei, LI Zhiqiang, et al. Effect of diffusion bonding defect on mechanical properties of Ti-6Al-4V alloy[J]. *Aeronautical Manufacturing Technology*, 2017, 60(18): 74-78.

[3] LECUN Y, KAVUKCUOGLU K, FARABET C. Convolutional networks and applications in vision[C]// *ISCAS. Proceedings of 2010 IEEE International Symposium*, 2010.

[4] ZHANG Q, YANG L T, CHEN Z, et al. A survey on deep learning for big data[J]. *Information Fusion*, 2018, 42: 146-157.

[5] 真彤, 祁国宁. 敏捷制造的实施方法探讨[J]. *中国机械工程*, 1999, 10(7): 760-764.

ZHEN Tong, QI Guoning. Discussion on the implementation methods of agile manufacturing[J]. *Chinese Journal of Mechanical Engineering*, 1999, 10(7): 760-764.

[6] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from over fitting[J]. *Journal of Machine Learning Research*, 2014, 15: 1929-1958.

[7] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks[C]// *AISTATS'2010*. 2010: 249-256.

[8] SAXE A M, MCCLELLAND J L, GANGULI S. Exact solutions to the nonlinear dynamics of learning in deep linear neural networks[C]// *International Conference on Learning Representations, Canada*, 2013.

[9] WILSON D R, MARTINEZ T R. The general inefficiency of batch training for gradient descent learning[J]. *Neural Networks*, 2003, 16(10): 1429-1451.

[10] HINTON G E. Learning multiple layers of re-presentation[J]. *Trends in Cognitive Sciences*, 2007, 11(10): 428-434.

通讯作者: 胡京徽, 助理工程师, 研究方向为机器学习、计算机视觉、模型驱动软件工程等, E-mail: hujinghui@buaa.edu.cn.

(责编 大漠)