

蜂窝夹层结构缺陷红外热成像检测及缺陷分类

唐庆菊 谷卓妍 卜红茹 徐贵鹏

Infrared thermal imaging detection and defect classification of honeycomb sandwich structure defects

Tang Qingju, Gu Zhuoyan, Bu Hongru, Xu Guipeng

在线阅读 View online: <https://doi.org/10.3788/IRLA20230631>

您可能感兴趣的其他文章

Articles you may be interested in

CFRP/Al蜂窝结构缺陷巴克编码热波检测及匹配滤波

Barker coded thermal wave detection and matched filtering for defects in CFRP/Al honeycomb structure

红外与激光工程. 2021, 50(10): 20210050 <https://doi.org/10.3788/IRLA20210050>

红外目标检测网络改进半监督迁移学习方法

An improved semi-supervised transfer learning method for infrared object detection neural network

红外与激光工程. 2021, 50(3): 20200511 <https://doi.org/10.3788/IRLA20200511>

航空复合材料内部缺陷差动式激光红外热成像检测

Detection of internal defects in aviation composites with differential laser infrared thermal imaging

红外与激光工程. 2019, 48(5): 504003 <https://doi.org/10.3788/IRLA201948.0504003>

基于迁移学习SAE的无人机目标识别算法研究

Research on UAV target recognition algorithm based on transfer learning SAE

红外与激光工程. 2018, 47(6): 626001 <https://doi.org/10.3788/IRLA201847.0626001>

CFRP层板缺陷红外热波雷达成像检测概率研究

Study on probability of detection for CFRP laminate defect using infrared thermal wave radar imaging

红外与激光工程. 2017, 46(10): 1004005 <https://doi.org/10.3788/IRLA201784.1004005>

超光滑表面缺陷的分类检测研究

Study on classification and detection of supersmooth surface defects

红外与激光工程. 2019, 48(11): 1113003 <https://doi.org/10.3788/IRLA201948.1113003>

蜂窝夹层结构缺陷红外热成像检测及缺陷分类

唐庆菊, 谷卓妍, 卜红茹, 徐贵鹏

(黑龙江科技大学 机械工程学院, 黑龙江 哈尔滨 150022)

摘要: 为实现 GFRP/NOMEX 蜂窝夹层结构常见缺陷的准确分类, 基于红外热成像无损检测技术, 采用卷积神经网络及迁移学习技术建立 GFRP/NOMEX 蜂窝夹层结构缺陷的分类模型, 比较微调的 VGG16、MobileNetV2、ResNet50、InceptionV3、DenseNet201 模型对于缺陷的分类效果, 结果表明以上模型针对 GFRP/NOMEX 蜂窝夹层结构蒙皮脱粘缺陷、夹层脱粘缺陷、积水缺陷、堵胶缺陷及健康区域均可实现准确的识别分类, 其准确率均在 94% 以上。其中基于 VGG16 的两种迁移学习模型及 ResNet50 的迁移学习模型对于此数据集的分类效果优于其余几种经典模型的迁移学习网络, 其准确率分别达到 99.94%、99.10%、98.95%, 五个类别 φ 值得分均高于 96%, 可实现缺陷区域及健康区域的有效分类。

关键词: 红外热成像; 缺陷分类; 迁移学习; 蜂窝夹层结构

中图分类号: TN219 **文献标志码:** A **DOI:** 10.3788/IRLA20230631

0 引言

蜂窝夹层结构复合材料由于其优异的物理性质被广泛应用于航空航天飞行器的主次承力结构中, 由于夹层结构制备工艺复杂以及常在较为恶劣的服役环境中工作, 导致其易产生分层、脱粘、积水、堵胶等缺陷^[1-2], 其中最为常见的是蒙皮与胶层、胶层与蜂窝芯的脱粘缺陷。这些缺陷或损伤通常面积较小、相互不连续、比较隐蔽, 因此在导致材料失效前并不易被发现, 但当材料内部或外部对试件施加干扰时, 例如外部震动、冲击、内应力等突然出现, 对结构造成致命性威胁, 严重影响了相关构件的正常使用, 威胁人员安全, 造成一定的经济损失, 因此如何能够快速、高效和准确地检测与识别出 GFRP/NOMEX 蜂窝夹层结构的内部缺陷已经成为相关领域的研究热点和难点。

红外无损检测^[3-5]近年来发展迅速, 相较于传统的检测方法具有结果直观、检测面积大等优点。其物理基础是扫描记录或观察被检构件表面上由于缺陷与材料不同热物理特性所引起的温度变化, 从而实现

缺陷的检测。其中光脉冲红外热成像是研究最多和使用最广的方法之一, 即向试件表面注入高能脉冲, 使用红外热像仪记录试件表面温度变化, 根据热传导理论得到缺陷相关信息。对于不同类型的缺陷, 红外图像上所展示的信息各不相同, 其本质是由于不同类型缺陷热物性参数不同, 受激励后其表面温度场不同, 即产生冷点或热点, 最终通过将红外热图的温度转化为颜色进行可视化。

针对复合材料的缺陷检测, 近年来多使用机器视觉代替人类视觉的方法, 通过对数据进行标注, 采用深度学习进行模型训练来实现缺陷的识别, 成本低, 且具有较强的高效性和灵活性。深度卷积神经网络^[6]是一种经典的多层构架前馈人工神经网络, 具有较强的特征提取能力、准确率高、鲁棒性好, 识别效率高等优点, 因此近年来被广泛应用于缺陷分类、目标检测等图像处理任务。但成熟的卷积神经网络模型通常较为复杂, 需学习参数较多, 导致其训练复杂, 耗时较多, 且需要大量的训练样本, 同时对硬件要求高。

迁移学习^[7-8]是借助已有领域的知识对不同但相

收稿日期: 2023-11-13; 修订日期: 2024-01-08

基金项目: 黑龙江省自然科学基金杰出青年项目 (JQ2023E011)

作者简介: 唐庆菊, 女, 教授, 博士, 主要从事红外热波无损检测与评价技术方面的研究。

关领域问题求解的机器学习方法。将已训练好的网络进行调整使其适应新的任务, 无需将网络从头训练, 且对硬件要求低, 训练速度快, 因此近年来迁移学习被广泛应用于诸多领域, 并且都达到了较好的效果。

1 数据集搭建

1.1 样本采集

1.1.1 检测原理

采用 FLIR A655 SC 红外热像仪、聚光卤素灯、调光器、数据采集卡、LabVIEW 软件搭建反射式脉冲红外热成像无损检测系统, 如图 1 所示为原理图, 通过 LabVIEW 软件产生脉冲波形, 信号经数据采集卡传至调光器, 调光器接收信号控制卤素灯对 GFRP/NOMEX 蜂窝夹层结构试件进行主动脉冲热激励, 由于缺陷处与无缺陷处热物性参数存在差异, 因此不同类型缺陷对应试件表面温度表现不同, 根据缺陷传热能力的差异可将缺陷分为隔热缺陷与导热缺陷, 隔热缺陷处对应表面温度高于无缺陷处, 即试件表面产生热点, 而导热缺陷与之相反, 试件表面产生冷点, 不同类型缺陷反射式红外热波检测传热过程如图 2 所示, 不同类型缺陷处对应表面温度曲线变化如图 3 所示。




图 1 脉冲红外热波无损检测原理

Fig.1 Pulsed infrared thermal wave nondestructive testing principle





图 2 不同类型缺陷处传热过程。(a) 无缺陷试件; (b) 含隔热性缺陷试件; (c) 含导热性缺陷试件

Fig.2 The process of heat transfer at different types of defects. (a) Specimen without defects; (b) Specimen containing thermal insulation defects; (c) Specimens containing thermal conductivity defects

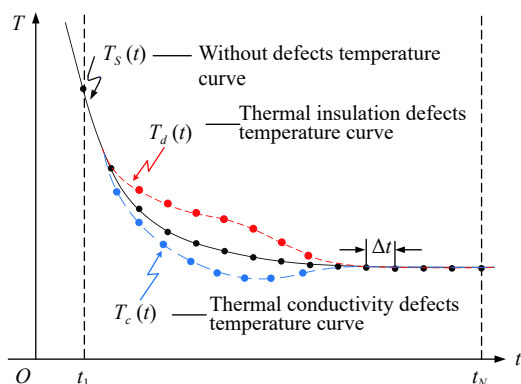


图 3 不同类型缺陷对应表面温度变化曲线示意图

Fig.3 The schematic diagram of surface temperature change curve corresponding to different types of defects

1.1.2 试件设计

被检测试件为含有不同缺陷类型的 GFRP/NOMEX 蜂窝夹层结构, 分别记为 #A1、#A2、#A3。试件外形尺寸均为 160 mm×140 mm×5.2 mm, 上下蒙皮为厚度 0.5 mm 的玻璃纤维增强复合材料, 通过上下两层 0.1 mm 环氧树脂与 4 mm 的芳纶纸蜂窝粘结而成, 3 个试件内含有堵胶、积水、上蒙皮与胶膜脱粘 (记为“脱粘 1”) 及胶膜与蜂窝脱粘 (记为“脱粘 2”) 共 4 类缺陷。其中采用打平底盲孔的方式模拟脱粘缺陷; 向蜂窝内注水及环氧树脂模拟积水及堵胶缺陷。模拟缺陷试件如图 4 所示, 试件的具体缺陷类型见表 1。



图 4 试件

Fig.4 Test specimen

表 1 试件缺陷类型

Tab.1 Defects type of specimen

Column test specimen	The first column	The second column	The third column	The fourth column
#A1	Water accumulation defects	Plugging glue defects	Plugging glue defects	Plugging glue defects
#A2	Water accumulation defects	Plugging glue defects	Bonding defects 1	-
#A3	Water accumulation defects	Bonding defects 2	Bonding defects 1	-

1.1.3 试验

卤素灯向试件表面发出脉冲热激励,热流在试件内部传播流动,试件内部的缺陷将会对热流的传播产生影响,其中脱粘缺陷为隔热缺陷,实际为胶膜与 Nomex 和 GFRP 蒙皮脱粘,即试件层间存在空气,而空气的导热系数较小,热流传播受到阻碍,反应在试件表面为热点。积水缺陷实际为服役过程中蜂窝内部进水,堵胶缺陷为蜂窝夹层结构加工过程中局部环氧树脂过量,导致蜂窝内存在环氧树脂。健康试件蜂窝内部的介质为空气,当热流向内部传播时,由于水和胶的导热系数都远大于空气,导致试件表面产生冷点。红外热像仪实时记录试件表面激励及散热过程温度变化,最后通过颜色对试件表面温度场分布进行可视化。

设置脉宽为 15 s,卤素灯功率为 1800、1900、2000 W,采样频率为 20 Hz,采集时间为 30 s,对 GFRP/NOMEX 蜂窝夹层结构进行热成像检测试验。

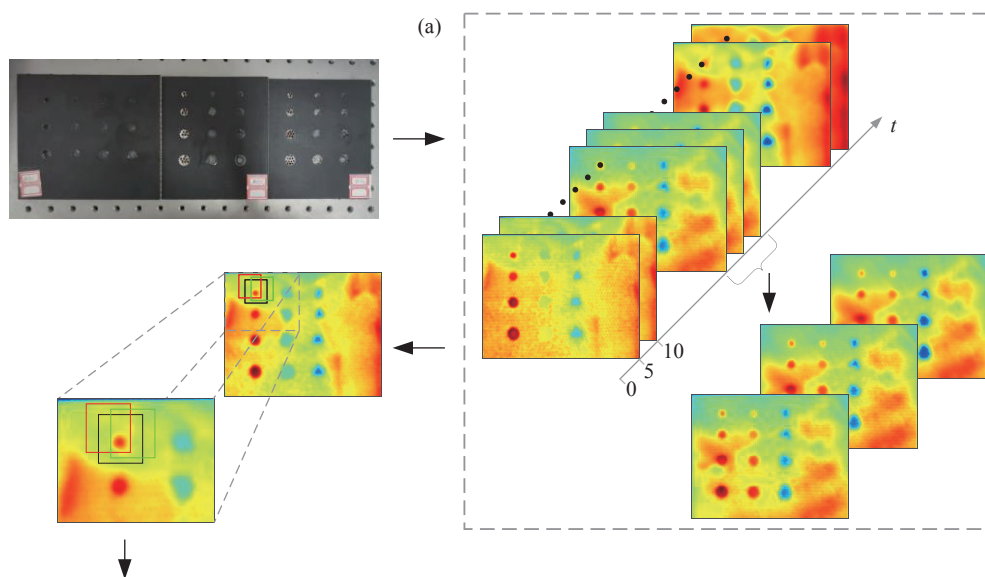
1.2 数据处理

1.2.1 数据采样

通过红外热像仪采集到的图像大小为 480 pixel×640 pixel,共计 600 帧热图,激励脉宽为 15 s,其中前 300 帧为升温阶段,后 300 帧为散热阶段。由于试件表面温度达到峰值附近的热图中缺陷对比度较高,冗余噪声少,缺陷信息较为明显,因此取其中若干帧热图对缺陷及健康区域采样,建立 5 分类深度学习数据集。为保证缺陷信息的完整,最终采样大小为 90 pixel×90 pixel 的缺陷和健康图像,数据采样过程如图 5 所示。

1.2.2 数据扩增

由于试件以及其缺陷种类、个数有限,为了保证网络训练精度以及防止深度学习网络在学习过程中出现过拟合现象,现对已有数据集进行图像扩增,采用旋转 90°、180°、270°、水平翻转、竖直翻转和加入高斯噪声操作,提高模型泛化能力,扩增过程如图 5 所示。



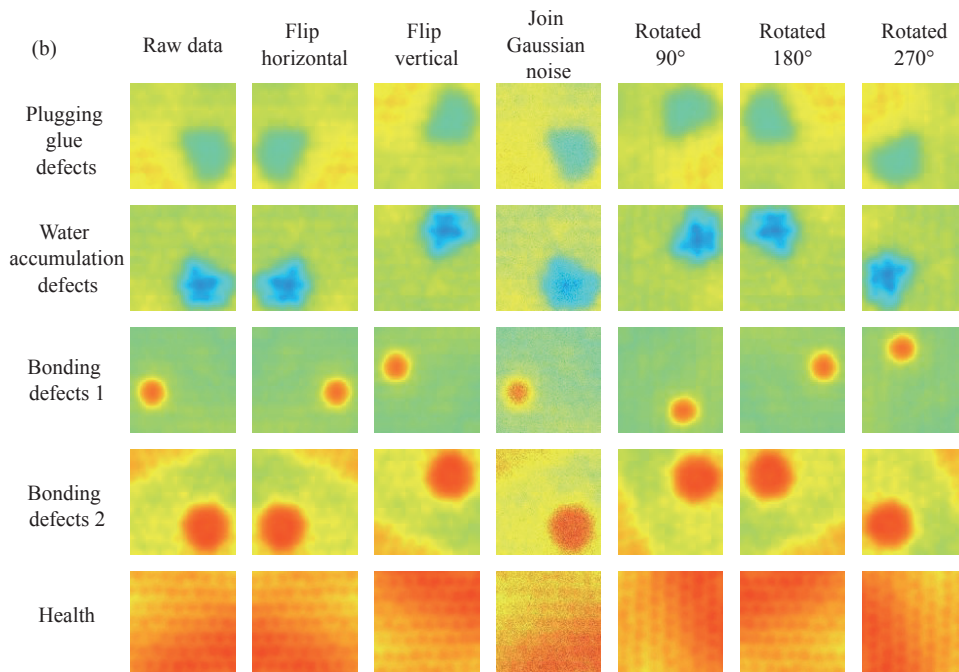


图 5 数据采集与扩增

Fig.5 Data acquisition and amplification

所示。经过扩增后的红外图像数据集共计 8064 幅图像样本,数据集各类型样本数及占比见表 2。

表 2 红外图像数据集缺陷种类样本数

Tab.2 The number of samples of different types of defects in the infrared image data set

Types of defects	Plugging glue defects	Water accumulation defects	Bonding defects 1	Bonding defects 2	Health
Sample size	2457	2079	1512	756	1260
Proportion	30.5%	25.8%	18.8%	9.4%	15.6%

1.2.3 数据集划分

将扩充后的数据集进行随机划分,将扩充后数据集的 60% 作为训练集,用于学习网络权重及偏置; 20% 作为网络训练的验证集,不参与梯度下降过程,只为调整网络时确定超参数提供参考; 20% 作为模型在未见数据上的模型评估,即测试集。

2 卷积神经网络

卷积神经网络是建立在多层感知机上的一种前馈神经网络,具有强大的特征提取能力,因此被大量应用于处理视觉任务,例如缺陷检测、目标识别、语义分割等。此外,卷积神经网络具有权值共享特质,

对于处理上百万的图像数据时,传统全连接神经网络需要大量的参数进行学习,而卷积神经网络则极大的节约计算资源,有效提高训练速度。

卷积神经网络处理图像数据时,首先通过多个卷积层、激活函数、池化层提取特征信息,再经过全连接层对结果进行识别分类,此过程为卷积神经网络的正向传播。将预测结果与目标标签比较,计算误差得到损失函数,损失函数作为一个监督信号指导修改网络模型参数,即通过将网络的权值和偏置向损失函数梯度下降的方向更新调整,此过程为反向传播,最大程度减小误差,不断迭代更新网络参数,以此完成网络的学习。

1) 卷积层

卷积操作作用于图像特征的提取,通过卷积核在特征图上移动,依次与特征图进行卷积操作,整张图像共用一个卷积核,共享其内部的权值与偏置,一个卷积核只能提取一个特征,因此为了提取一张图片的多个特征,增加卷积神经网络的表达能力,每个卷积层内都有多个卷积核。积水及脱粘缺陷经卷积后的特征图可视化如图 6 所示。

2) 激活层

神经网络通过激活层为网络添加非线性因素,为卷积的结果做非线性映射,若网络没有激活层,则无

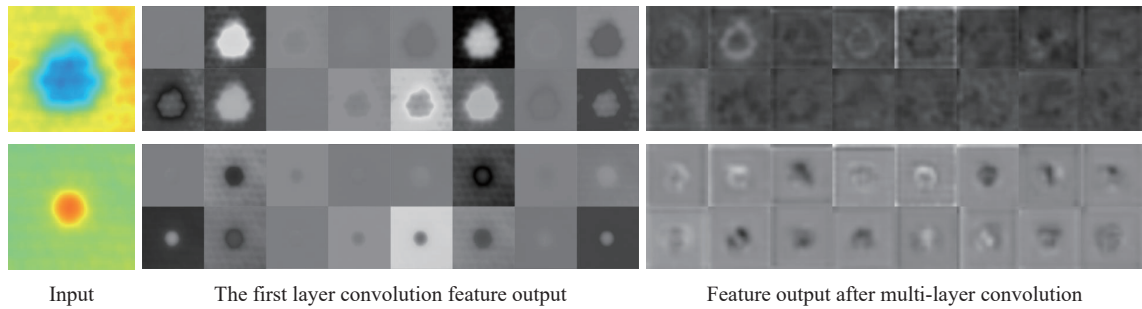


图 6 特征图可视化

Fig.6 Feature map visualization

论有多少个隐含层,网络都是线性映射,无法解决非线性问题。ReLU 线性整流函数是常用的激活函数,具体表达式如公式 (1) 所示。

$$f(x) = \max(0, x) \quad (1)$$

ReLU 具有单侧抑制性,也就是当负值输入时,输出为零,即此神经元不会被激活,正值输入时则不变,使得神经网络中的神经元也具有了稀疏激活性,更好使网络拟合训练数据。同时 ReLU 由于非负区间的梯度为常数,不会出现梯度消失问题,使模型稳定收敛。

3) 池化层

池化层的主要功能为压缩特征图,减少网络复杂程度及下一次的参数及计算量,防止过拟合,增大感受野。同时,池化的过程也会丢失一些信息,降低了分辨率。常见的池化操作有最大池化和平均池化。

3 迁移学习

卷积神经网络浅层捕获的是一些轮廓边缘等普

遍特征,在浅层学习的特征具有通用性,因此在出现样本少、不足以训练大型网络时,可以选择将已经通过大量数据训练好的网络进行迁移学习。文中将应用基于模型迁移学习中的微调技术对 GFRP/NOMEX 夹层结构缺陷进行分类。冻结浅层的结构,保持权重及偏置参数不变,只训练模型最后修改或添加的网络,让模型关注缺陷样本的特征,节省训练时间,增强模型泛化能力,避免直接应用小样本进行大型网络训练导致网络过拟合。

ImageNet 是广泛应用于计算机视觉领域的大型数据库,其中包含了 100 万幅图,共 1000 个类别,由于其数据量庞大,且分类种类繁多,因此在 ImageNet 数据库经过预训练的模型具备提取缺陷特征的能力。文中将在 ImageNet 数据集上训练得到的多个经典预训练模型(如 VGGNet^[9-10], ResNet^[11]等)进行微调操作,对比 GFRP/NOMEX 蜂窝夹层结构缺陷红外图像的分类效果。如图 7 所示,具体操作为冻

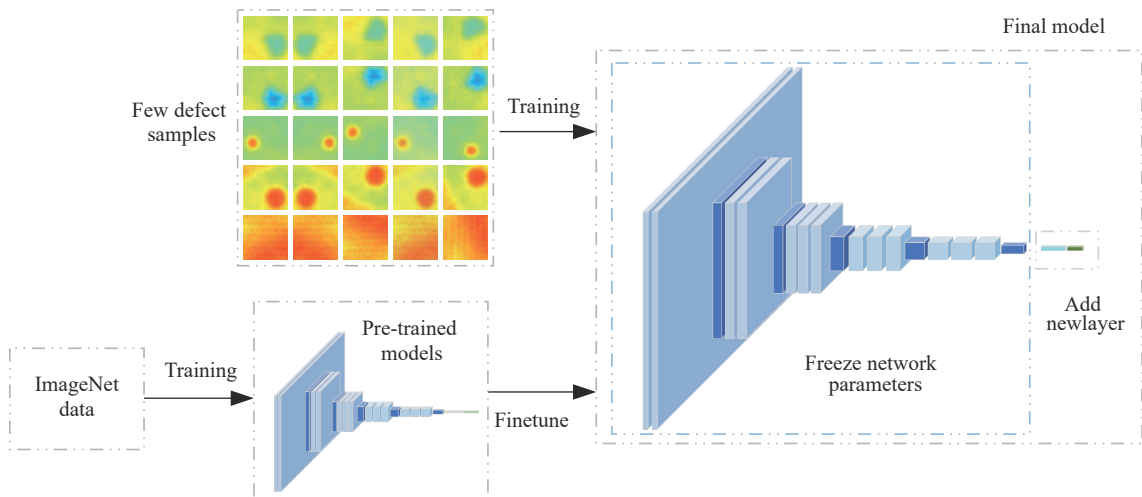


图 7 迁移学习过程

Fig.7 Transfer learning process

结预训练模型的前若干层网络参数,用于图像特征提取,替换或修改后若干层的网络,如添加适合新任务的全连接层等,从而变成一个新的网络,最后使用缺陷红外数据集对微调后的模型进行训练,实现 GFRP/NOMEX 蜂窝夹层结构缺陷的分类。

3.1 VGG16 微调网络结构建立

VGG16 由 1 个输入层、1 个输出层、13 个卷积

层、5 个池化层和 3 个全连接层组成,其中含有参数的网络共有 16 层,网络使用的首个卷积核大小为 $3 \times 3 \times 3$,池化核大小为 2×2 ,现对 VGG16 网络进行两个迁移学习对比分析分类效果,改进后的 VGG-16-1 模型如图 8 所示,删除后 4 层网络,冻结网络剩余层中的权重及偏置参数,依次添加维度为 1×256 的全连接层进行降维处理,ReLU 激活函数,收敛速度快、计

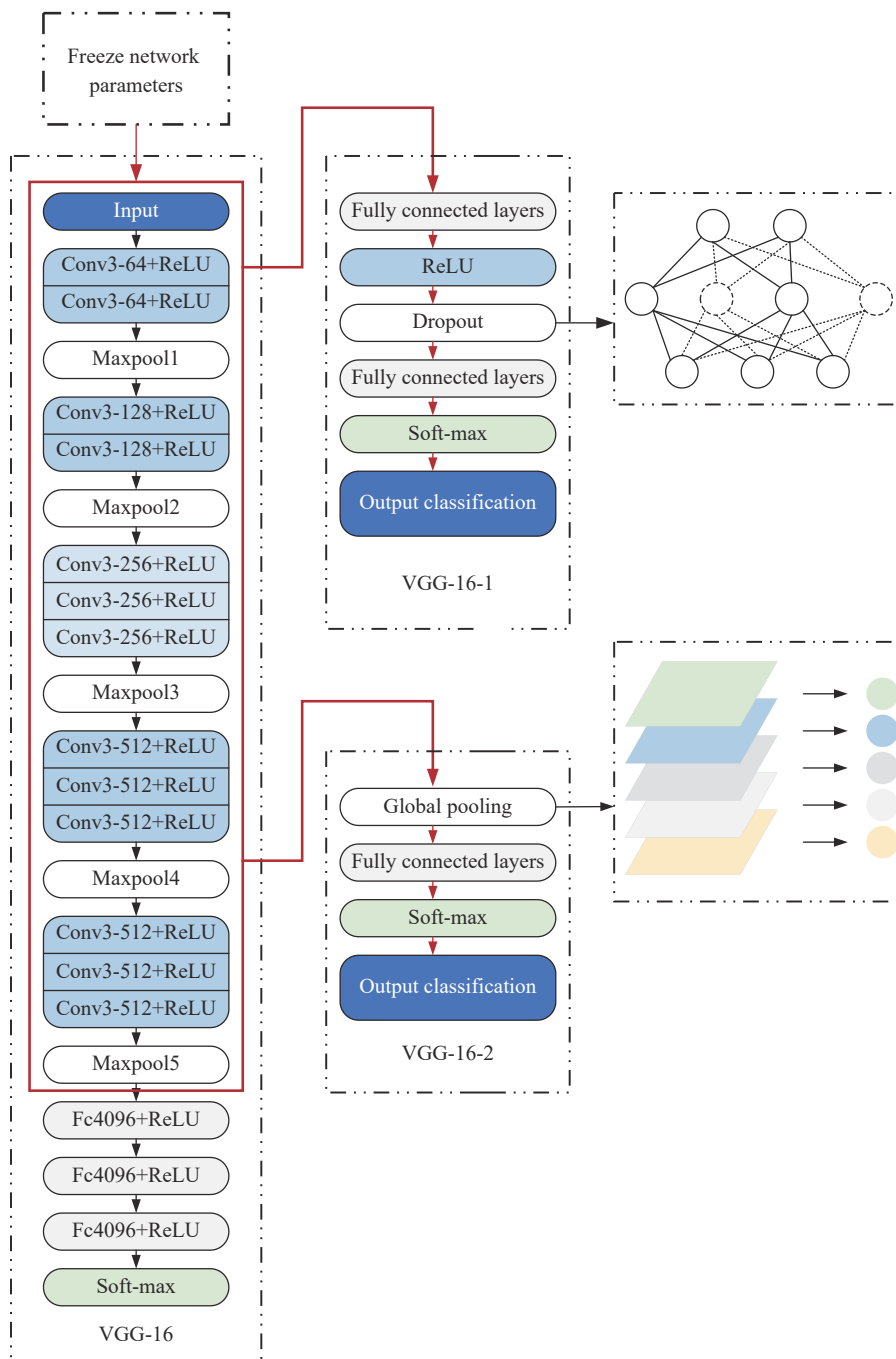


图 8 VGG-16 网络微调

Fig.8 VGG-16 network fine-tuning

算复杂度低; Dropout 层, 如图 8 所示, 使某些神经元以一定概率暂时从网络中丢弃, 避免网络过拟合, 提高模型泛化能力, 使其不会过于依赖某些局部特征; 由于数据集中的红外热图为 5 类, 因此添加一个维度为 1×5 的全连接层; 最后添加 Softmax 层计算分类概率, 以及分类输出层, 使其合并成一个新的网络。

VGG-16-2 模型为删除原模型的后四层网络, 并依次添加全局平均池化层、维度为 1×5 的全连接层、Softmax 层及分类输出层。其中全局平均池化层如图 8 所示, 是将上一层输出的三维矩阵的每个通道做平均值处理, 最后得到长度为上一层输出通道数的一维矩阵, 加强类别与特征图的联系, 与将上一层输出的特征图直接拉成一维相比, 极大程度上减少了网络参数, 一定程度上抑制在后续的全连接层中发生过拟合现象。

3.2 MobileNetV2 微调网络结构建立

MobileNetV2^[12-13] 是在 2018 年被提出的轻量化 CNN, 文中将 MobileNetV2 预训练模型应用迁移学习的微调技术, 先将网络的最后一层分类器去除, 并冻结网络中剩余的权重及偏置参数, 依次添加 Dropout 层、全局平均池化层、维度为 1×5 的全连接层、Softmax 层以及分类输出层。

3.3 ResNet50、InceptionV3、DenseNet201 微调网络结构建立

对在 ImageNet 上预训练过的 ResNet50、InceptionV3^[14]、DenseNet201^[15] 网络进行微调, 将预训练网络的后三层去除, 并冻结网络中剩余的权重及偏置参数, 添加适用于本研究预测任务的 1×5 全连接层、Softmax 层及分类输出层。

4 模型训练与结果分析

训练采用的处理器为 13th Gen Intel(R) Core(TM) i9-13900 HX (32 CPUs), ~2.2 GHz, 内存 16 GB。模型初始学习率设置为 0.000 05, 每迭代 200 次衰减 50%。由于计算机的 GPU 计算能力有限, 因此为了在有限的计算能力下提高训练速度, 将训练时每次的迭代处理的图像数量设置为 200, 即 batch_size 设置为 200。由于训练集为 4838 张图片, 因此每轮迭代 24 次, 共训练 50 个轮次。模型梯度下降优化器均配置为 SGDM, 损失函数为交叉熵函数, 为了判断分类

模型是否出现过拟合现象, 训练集进行两次迭代训练后进行一次验证, 观察验证集的准确率和损失情况。

4.1 不同模型训练效果对比

6 种迁移学习模型的训练过程如图 9 所示。由曲线可知, 模型在验证集上的准确率和损失率曲线整体趋势与训练集相似, 表明训练过程中均未出现过拟合现象。

其中 VGG-16-1 模型的损失起始为 6.437 7, 经 64 次迭代后, 训练集和验证集损失均低于 0.1, 经 21 轮迭代后稳定低于 0.01, 最终第 50 轮验证集损失达到 0.001 2; 模型准确率由起始的 0.24 经 16 次迭代达到 90% 以上, 10 轮迭代后训练集与验证集准确率稳定高于 99%, 最终 50 轮次时模型准确率达到 99.94%。

VGG-16-2 网络起始损失为 2.785 6, 经 13 轮迭代后测试集与验证集损失低于 0.2, 最终第 50 轮验证集损失为 0.038 3, 但相较于 VGG-16-1 网络, 其训练过程中一直存在较大波动, 网络起始准确率为 14.5%, 9 轮次迭代后准确率稳定高于 90%, 最终第 50 轮次网络验证集准确率达到 99.07%, 尽管迭代次数达到 50 轮次, 网络训练集 Accuracy 和 Loss 依旧不稳定。

ResNet50 迁移学习模型的起始损失为 1.815 7, 经 50 次迭代后其训练集与验证集损失稳定低于 0.5, 经 27 轮迭代后稳定低于 0.1, 最终第 50 轮验证集损失达到 0.058 1; 其起始准确率为 19.15%, 经 76 次迭代后准确率高于 90%, 24 轮迭代后验证集与测试集准确率均稳定高于 98%, 最终第 50 轮次网络验证集准确率达到 99.13%。

Densenet201 迁移学习模型起始损失为 2.021 1, 经 13 轮迭代后测试集与验证集损失低于 0.2, 33 轮迭代后稳定低于 0.1, 最终 50 轮次验证集损失达到 0.076, 可见网络收敛速度略慢; 网络起始准确率为 11%, 5 轮迭代后, 测试集与验证集准确率高于 90%, 27 轮迭代后稳定高于 97%, 最终 50 轮次验证集准确率达到 98.57%。

MobileNetV2 迁移学习模型起始损失为 2.341 5, 经 8 轮迭代后测试集与验证集损失稳定低于 0.2, 经 31 轮迭代后低于 0.1, 第 50 轮次验证集损失达到 0.084 6, 可见网络收敛速度较慢, 且训练曲线略有波动; 其网络准确率由起始的 17.50% 经 4 轮迭代后高于 90%, 21 轮迭代后稳定高于 95%, 最终验证集准确

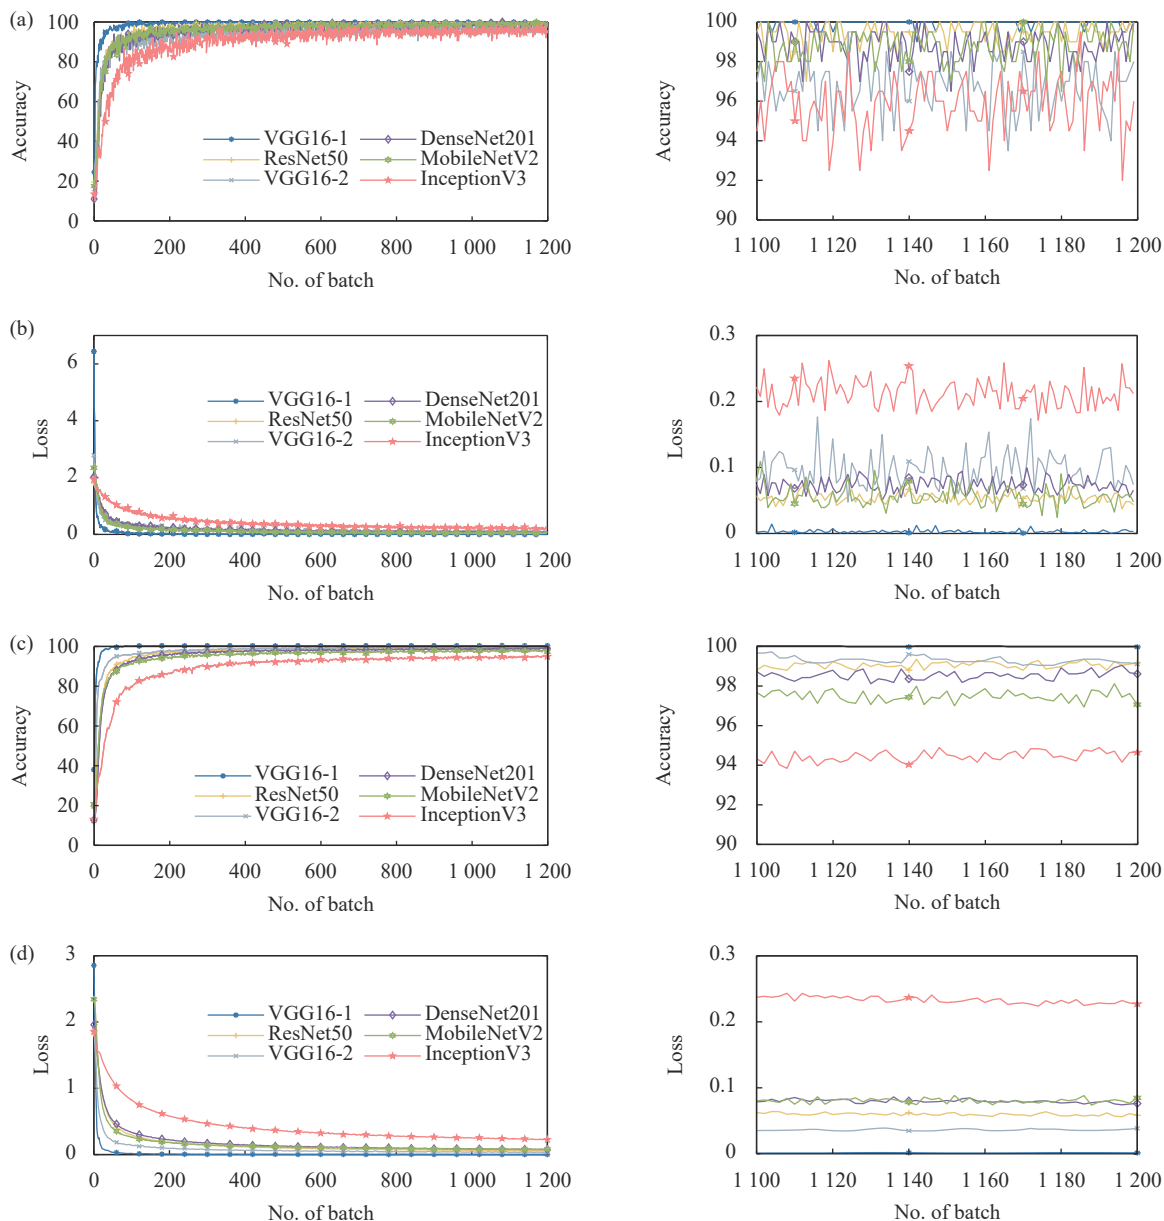


图 9 迁移学习模型训练过程。(a) 训练集 Accuracy; (b) 训练集 Loss; (c) 验证集 Accuracy; (d) 验证集 Loss

Fig.9 Transfer learning model training process. (a) Training set Accuracy; (b) Training set Loss; (c) Validation set Accuracy; (d) Validation set Loss

率达到 97.03%

InceptionV3 迁移学习模型起始损失为 1.938 5, 经 12 轮迭代后网络训练集与验证集损失均低于 0.5, 33 轮迭代后低于 0.3, 第 50 轮次验证集损失达到 0.226 9, 由此可知, 相较于以上几种迁移学习模型 Loss 收敛速度慢, 且网络不稳定, 波动性较大; 网络起始准确率为 13.5%, 经 15 轮迭代后稳定高于 90%, 最终 50 轮次迭代验证集准确率达到 94.61%。

综上所述, VGG16 及 ResNet50 迁移模型对于

GFRP/NOMEX 蜂窝夹层结构缺陷分类效果较优。其中 VGG-16-1 收敛速度快、网络稳定, 且对于缺陷的分类效果最好, 相较于 VGG-16-1 来说, VGG-16-2 网络收敛效果差于 VGG-16-1, 且在训练后期网络依然存在较大波动, VGG16 的两种网络训练消耗时间相近。ResNet50 网络模型分类效果虽略差于 VGG16 模型分类效果, 但由于 ResNet50 网络模型的学习参数相较于 VGG16 网络较少, 因此其训练速度远快于 VGG16。各网络具体训练消耗时间见表 3。

表 3 迁移学习不同分类模型性能比较

Tab.3 Performance comparison of different classification models of transfer learning

Deep learning model	Learning rate	Iteration cycle	Training time/s
VGG-16-1	0.00005	50	12500
VGG-16-2	0.00005	50	12515
ResNet50	0.00005	50	4160
Densenet201	0.00005	50	15437
MobileNetV2	0.00005	50	3765
InceptionV3	0.00005	50	6689

4.2 结果

的分类结果,其统计了 GFRP/NOMEX 蜂窝夹层结构缺陷热图测试集的分类情况。

4.2.1 混淆矩阵

如图 10 所示为六种迁移学习模型对测试集数据

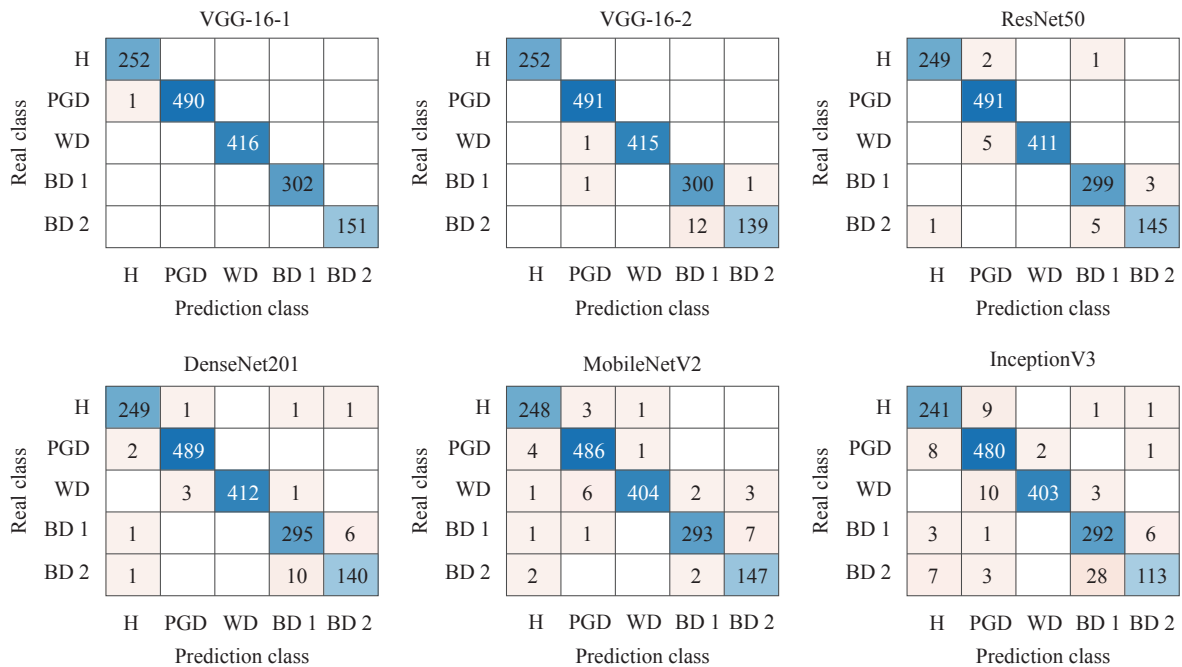


图 10 迁移学习模型混淆矩阵

Fig.10 Transfer learning model confusion matrix

4.2.2 性能评估

文中采用准确率及φ值来对迁移模型进行评估。试验任务为 5 分类,依次将每类别看作阳性 (Positive),其余均为阴性 (Negative),若样本预测为阳性且真实为阳性,则将其称为真阳性 (Ture Positive),若预测为阳性而真实为阴性则称为假阳性 (False Negative),真阴性与假阴性则同理。将预测为阳性的样本中存在多少真实阳性样本称之为精确率 (Precision),将样本

中的实际阳性存在多少被预测正确称之为召回率 (Recall),其数学表达式如公式 (2)~(3) 所示。Accuracy 为准确率,即对于整体而言,预测正确的比率。其数学表达式如公式 (4) 所示。值为精确率和召回率的调和平均数,其数学表达式如公式 (5) 所示。

$$Precision = \frac{Ture\ Positive}{Ture\ Positive + False\ Positive} \quad (2)$$

$$Recall = \frac{Ture\ Positive}{Ture\ Positive + False\ Negative} \quad (3)$$

$$Accuracy = \frac{Ture\ Positive + Ture\ Negative}{Ture\ Positive + False\ Positive + Ture\ Negative + False\ Negative} \quad (4)$$

$$\varphi = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (5)$$

各模型在对 GFRP/NOMEX 蜂窝夹层结构缺陷红外热图 5 类别分类任务上的 φ 值得分及准确率见表 4。其中 VGG16 和 ResNet50 迁移学习模型在所有类别的分类中均表现较好,其 φ 值均在 95% 以上,准确率 98% 以上,可以有效完成对于 GFRP/NOMEX 蜂

窝夹层结构缺陷的分类任务。其中 VGG-16-1 仅在堵胶缺陷与积水缺陷的分类中出现预测错误,分类效果最优。除了网络分类效果的因素外,导致产生分类错误的原因还有网络训练的样本量较小,可以通过获取大量的训练数据和提供大量的此类图像对网络进行训练,有效提高分类效果,从而解决误分类问题。

表 4 各迁移学习模型针对每种缺陷的 φ 值及准确率

Tab.4 The φ value and accuracy of each transfer learning model for each defect

Transfer learning model	φ value of different defects types					Predictive Accuracy
	Plugging glue defects	Water accumulation defects	Bonding defects 1	Bonding defects 2	Health	
VGG-16-1	99.80%	99.90%	100%	100%	100%	99.94%
VGG-16-2	100%	99.79%	99.88%	97.72%	95.53%	99.10%
ResNet50	99.20%	99.29%	99.40%	98.51%	96.99%	98.95%
DenseNet201	98.61%	99.39%	99.52%	96.88%	93.96%	98.33%
MobileNetV2	97.64%	98.48%	98.30%	97.83%	95.45%	98.01%
InceptionV3	94.32%	96.58%	98.18%	93.29%	83.09%	94.85%

5 结 论

文中采用的 VGG16、ResNet50、DenseNet201、MobileNetV2、InceptionV3 的微调迁移学习模型均对 GFRP/NOMEX 蜂窝夹层结构缺陷实现了较好的分类,其中基于 VGG16、ResNet50 的微调模型效果优于其余几种经典模型的迁移学习网络,其准确率分别达到 99.94%、99.10%、98.95%。5 类别 φ 值得分均高于 96%。对比 VGG16 网络的两种微调模型,其中 VGG-16-1 的准确率及 φ 值均高于 VGG-16-2,网络收敛速度快且稳定,达到了较好的分类效果,ResNet50 虽整体得分不及 VGG-16-1,但其网络训练速度快,同时也可以达到较好的分类效果。综上表明,通过对预训练的经典卷积神经网络模型进行微调的迁移学习操作,可以在降低训练成本、提高训练速度的前提下针对 GFRP/NOMEX 蜂窝夹层结构不同类型缺陷实现较好的分类,同时也可以避免由于样本不足直接对经典网络进行训练出现过拟合或欠拟合的现象。为 GFRP/NOMEX 蜂窝夹层结构缺陷的定量化研究提供了一定的参考借鉴。

参考文献:

[1] Guo Xingwang. Comparative study on pulsed thermography and

modulated thermography of composite honeycomb panels [J]. *Acta Materiae Compositae Sinica*, 2012, 29(2): 172-179. (in Chinese)

[2] Fan Weiming. Research on the technology of GFRP/NOMEX honeycomb sandwich structure defects detection using infrared thermal wave testing method[D]. Harbin: Heilongjiang University of Science and Technology, 2022. (in Chinese)

[3] Wei Jiacheng, Liu Junyan, He Lin, et al. Recent progress in infrared thermal imaging nondestructive testing technology [J]. *Journal of Harbin University of Science and Technology*, 2020, 25(2): 64-72. (in Chinese)

[4] Bu Chiwu, Zhao Bo, Liu Tao, et al. Barker coded thermal wave detection and matched filtering for defects in CFRP/Al honeycomb structure [J]. *Infrared and Laser Engineering*, 2021, 50(10): 20210050. (in Chinese)

[5] Li Yanhong, Jin Wanping, Yang Danggang, et al. Thermal wave nondestructive testing of honeycomb structure [J]. *Infrared and Laser Engineering*, 2006, 35(1): 45-48. (in Chinese)

[6] LeCun Y, Bengio Y, Hinton G. Deep learning [J]. *Nature*, 2015, 521(7553): 436-444.

[7] Pan S J, Yang Q. A survey on transfer learning [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2010, 22(10): 1345-1359.

[8] Yosinski J, Clune J, Bengio Y, et al. How transferable are features in deep neural networks? [C]//NIPS, 2014, 2: 3320-

- 3328.
- [9] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [C]// ICLR, 2015: 1-14.
- [10] Xu Jinghui, Shao Mingye, Wang Yichen, et al. Recognition of corn leaf spot and rust based on transfer learning with convolutional neural network [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2020, 51(2): 230-236, 253. (in Chinese)
- [11] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [12] Feng Xiao, Li Dandan, Wang Wenjun, et al. Image recognition of wheat leaf diseases based on lightweight convolutional neural network and transfer learning [J]. *Journal of Henan Agricultural Sciences*, 2021, 50(4): 174-180. (in Chinese)
- [13] Sandler M, Howard A, Zhu M, et al. Mobilenetv2: Inverted residuals and linear bottlenecks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.
- [14] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 2818-2826.
- [15] Cai Peng, Yang Lei, Luo Junli. Fabric defect detection method based on fusion of convolutional neural network models [J]. *Journal of Beijing Institute of Fashion Technology (Natural Science Edition)*, 2020, 40(1): 55-62. (in Chinese)

Infrared thermal imaging detection and defect classification of honeycomb sandwich structure defects

Tang Qingju, Gu Zhuoyan, Bu Hongru, Xu Guipeng

(School of Mechanical Engineering, Journal of Heilongjiang University of Science and Technology, Harbin 150022, China)

Abstract:

Objective In order to realize the accurate classification of GFRP/NOMEX honeycomb sandwich structure defect types, an infrared thermal imaging detection system was built to collect heat maps of defects and healthy areas, and a GFRP/NOMEX honeycomb sandwich structure defect classification model was constructed by using convolutional neural network and transfer learning technology to realize quantitative detection of defect categories.

Methods The experimental study of pulse infrared thermal imaging detection was carried out on the specimen. The training data set was constructed using the data obtained from the experiment, and the fine-tuned convolutional neural network model after transfer learning was trained to realize the quantitative detection of defect categories. Firstly, GFRP/NOMEX honeycomb sandwich structure specimens with delamination, debonding, water accumulation and glue plugging defects were prefabricated, and a pulsed infrared thermal wave detection system was built. The FLIR A655SC infrared thermal imager was used to collect the surface temperature distribution field of the specimens under pulse excitation. Secondly, the defects in the heat map are cut into 90 pixel×90 pixel, and the data are expanded by rotating 90°, 180°, 270°, horizontal flipping, vertical flipping and adding Gaussian noise operations. The pre-trained VGG16, MobileNetV2, ResNet50, InceptionV3, and DenseNet201 convolutional neural network models use transfer learning technology to fine-tune the back-layer structure of the network. Finally, the constructed data set is randomly divided into training set, verification set and test set, and the network is trained. The value φ and *Accuracy* are used as evaluation indexes to evaluate the generalization ability and classification effect of the model.

Results and Discussions The VGG16, MobileNetV2, ResNet50 network, InceptionV3 and DenseNet201

network fine-tuned models based on transfer learning technology are trained (Fig.9). The VGG-16-1 network model has the fastest convergence speed, the network is stable, and the training process has no large fluctuations. At the same time, the confusion matrix is used to describe the classification results of the test set data by the six networks (Fig.10). It can be seen that the six models can realize the classification task of five categories of defects prefabricated by GFRP/NOMEX honeycomb sandwich structure. The values of φ and *Accuracy* are shown (Tab.4). The classification *Accuracy* of VGG16 and ResNet50 fine-tuned models reaches 99.94%, 99.10% and 98.95% respectively, and the scores of five categories of φ are all higher than 96%. Compared with the two fine-tuning models of VGG16 network, the *Accuracy* and value of VGG-16-1 are higher than those of VGG-16-2. VGG-16-1 has only one misjudgment for the 1 612 defect data of the test set, and the network convergence speed is fast and stable, achieving a better classification effect. Although the overall score of ResNet50 is not as good as VGG-16-1, its network training speed is fast and can also achieve better classification effect.

Conclusions The data set is constructed by using the real infrared images collected by the infrared thermal imager detection test, and the data is expanded for small samples. Based on the transfer learning technology, the network model structures of VGG16, MobileNetV2, ResNet50, InceptionV3 and DenseNet201 are fine-tuned, and the stability and convergence speed of the training process are compared and analyzed. Besides, the performance of the network was evaluated using a test set that did not participate in the training. The results show that by fine-tuning the transfer learning operation of the pre-trained classical convolutional neural network model, different types of defects of GFRP/NOMEX honeycomb sandwich structure can be well classified, and the quantitative detection of defect categories can be accurately realized.

Key words: infrared thermal imaging; defects classification; transfer learning; honeycomb sandwich structure

Funding projects: Natural Science Foundation of Heilongjiang Province (Q2023E011)