

基于深度学习的复合材料层合板损伤图像分类的研究

王正水¹, 赵刚^{1,2*}, 吴慧婕¹, 孙汤慧¹

¹南昌航空大学数学与信息科学学院, 江西 南昌

²南昌航空大学无损检测技术教育部重点实验室, 江西 南昌

收稿日期: 2024年1月22日; 录用日期: 2024年2月21日; 发布日期: 2024年2月27日

摘要

针对复合材料结构检测损伤检测问题, 本文提出了一种基于深度学习进行复合材料结构损伤检测的方法。本方法首先通过网络和文献收集复合材料结构图像资料, 建立数据集, 数据集包含损伤和未损伤的复合材料层合板图片; 然后采用三个卷积神经网络模型AlexNet、VGG和ResNet对损伤情况进行自动分类; 最后对三种预先训练过的网络架构的性能进行评估。实验结果表明, 在相同的实验条件下, AlexNet技术使用相对较小的图像数据集, 在合理的计算时间内能够成功地检测出损伤, 且测试精度最高, 复杂性较低。

关键词

复合材料, 卷积神经网络, 损伤检测, 深度学习

Research on Damage Image Classification of Composite Laminates Based on Deep Learning

Zhengshui Wang¹, Gang Zhao^{1,2*}, Huijie Wu¹, Tanghui Sun¹

¹School of Mathematics and Information Science, Nanchang Hangkong University, Nanchang Jiangxi

²Key Laboratory of Nondestructive Testing (Ministry of Education), Nanchang Hangkong University, Nanchang Jiangxi

Received: Jan. 22nd, 2024; accepted: Feb. 21st, 2024; published: Feb. 27th, 2024

*通讯作者。

文章引用: 王正水, 赵刚, 吴慧婕, 孙汤慧. 基于深度学习的复合材料层合板损伤图像分类的研究[J]. 计算机科学与应用, 2024, 14(2): 308-316. DOI: 10.12677/csa.2024.142031

Abstract

Composite structure detection technology has been exploring the efficient and fast damage detection technology. In this paper, an image-based NDT technique is proposed to detect composite material damage by deep learning. A dataset containing damaged and non-damaged composite laminate images was established through the network and literature data. Then three convolutional neural network models AlexNet, VGG and ResNet were used to automatically classify the damage conditions. Finally, the performance of three pre-trained network architectures is evaluated. The results show that AlexNet technology can successfully detect damage within a reasonable calculation time using a relatively small image dataset, with the highest test accuracy and low complexity.

Keywords

Composite Material, Convolutional Neural Network, Damage Detection, Deep Learning

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

复合材料是具有优良性能的新型材料，由多种属性不同材料组成，它比组成的原始材料更坚硬，更耐磨，更轻[1]。尽管复合材料有这些出色的优点，但是，复合材料结构在制造和使用的过程中容易受到各种损伤，从而显著地改变了它们的结构行为，最终导致结构失效或者使用寿命减少。为了保证复合材料结构的结构安全，当结构受损时，尽早知道损伤的具体情况是十分关键的。但是复合材料的各向异性特性使得一般的检测方法较难进行损伤评估。目前有许多无损检测技术 NDT (Non-Destructive Testing) 可用于检测复合材料结构内部的缺陷，如红外热成像检测[2]，声发射检测[3]等，虽然这些无损检测技术现如今很成熟，但是其中的大部分技术并不能按照最开始所设想的那样，直接使用检测设备进行无损检测，除了相关的仪器之外，还需要技术娴熟的操作员以及特定的检测环境。对于结构表面损伤，常采用目视检查技术。此外，目视检查也是许多现实实例中使用的最基本的 NDT 类型。因为它可以通过减少其他种类测试措施来节省检测所需要的时间和金钱，或者在某些特殊情况下同时减少对其他类型测试的需要，目视检查主要的优点就是速度快和相对承受性高[4]，但是检测的准确性也取决于检查员的判断能力。照明、检查的时间、检查员的疲劳和经验、环境条件等因素都会影响检查员的判断力，进一步影响目视检测的可靠性和检测成功的概率，随之就带来了健康和安全风险等问题。

近年来，随着科技发展，计算机硬件可以提供充足的算力，人们在自动化、数据分析、图像采集技术、人工智能技术等方面的取得了较大进步，使得低成本硬件的计算能力能够满足软件的计算需求，这也让搭建一个实用的自动视觉检查系统成为了可能[5]。Min Ma 等人[6]使用一维多尺度残差卷积神经网络对碳纤维增强聚合物 CFRPs (Carbon Fiber Reinforced Polymers) 进行损伤检测，基于仿真软件和实验获得 CFRPs 的损伤图像构造数据集。实验中训练所提出的网络结构，并根据测试数据集结果对该算法进行评估。该方法的决定系 R^2 数为 0.885，是该组网络架构中最高的网络结构，说明了模型的拟合效果较好。

过去提出的 CNNs (Convolutional Neural Networks) 在基于图像的数据上的应用中，所获取的图像都是通过 NDT 获得，如热成像和 X 射线，NDT 需要专业的设备以及经验丰富的操作员获取。这些研究的专

业性和难度较大，不利于其他学科的学者了解。为了解决这个难题，本文提出了一种基于深度学习的复合材料层合板损伤检测方法，通过在网络和相关文献中寻找损伤图像数据和未损伤图像数据构造数据集，训练多个神经网络并找出一个适用于评估复合材料层合板中的服役损伤情况的网络。最后通过优化算法结构提高网络的稳定性和准确性来实现有效的复合材料无损检测，大大降低复合材料结构检测成本，提升了复合材料结构的安全性。

2. 相关理论

2.1. 数据获取与增强

本文收集到的部分图像数据如图 1 所示，从不同厚度、材料、叠层、纹理等方面的复合材料层合板的文献中收集了一套全面的图像，包括未受损和受损伤图片。图像数据集总共包括 177 张损伤图片，63 张表面完整复合层合板图像图片图像在参考文献[7] [8] [9] [10] [11]中获得。

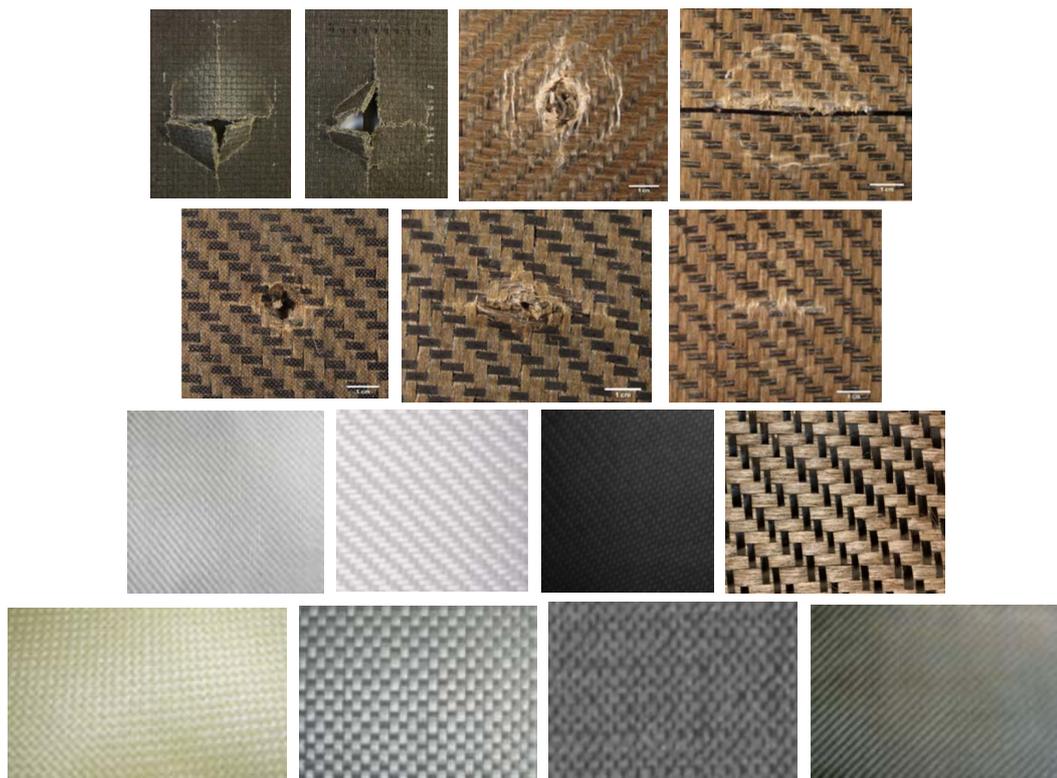


Figure 1. Picture of partial composite laminates

图 1. 部分复合层合板图

2.2. 数据增强

卷积神经网络(CNNs)的优秀泛化能力需要依赖大量的训练数据，而大量数据在工业实践中是难以获得的，数据增强通常被认为是解决这一问题的有效策略。数据增强能将较少的数据数量提升数倍，数据集样本的多样性和训练模型的鲁棒性都有足够的保障。训练过程中较少的样本所具备的特征信息不够充足，将会导致模型过度依赖某些属性，泛化能力不足，而使用数据增强方法可以避免这种情况出现。

现在，主流的增强策略分为几何变换和像素变换。几何变换包括平移，旋转和缩放等；像素变换方法有添加不同的噪声，调节亮度和改变饱和度等。在本文的实验研究中，将采用如下三个方法：第一个

是旋转方法，2次幅度为 90° 的角度旋转；第二个是翻转方法，将图像按照水平方向镜面翻转；第三个添加噪声，给图像加上高斯和椒盐噪声。

使用数据增强方法来获得更多的学习数据，每幅原始图像总共产生5张图像。由于采集图像的高宽比不一致，每张图像根据图像的自身条件进行不同形式的增强[12]。本文准备使用三种增强方法包括旋转 90° 和 180° ，水平翻转以及添加高斯噪声和椒盐噪声两种噪声，五种增强图像结果如图2所示。

在本文中，将2.1节所得到的240张图片随机选取145张作为训练集，48张作为验证集，47张作为测试集。通过上述的数据增强方法，使得训练集和验证集数据量被增加为原来的6倍，由193张变成1158张。



Figure 2. The result of the image augmentation

图2. 数据增强结果图

2.3. 基础网络模型

2.3.1. AlexNet 模型

AlexNet 网络是最常用的 CNN 架构之一，已经成功地训练了超过 100 万张图像，是广泛应用于图像分类的最有影响力的 CNN，并以 15.3% 的小错误率获得了 ImageNet LSVRC-2012 比赛的第一名[13]。该模型的意义在于能够提取有关图像的实际信息，并了解每一层中添加的特征。该网络总共包含 8 层学习层，网络的前大半部分使用卷积层和池化层来提取特征信息，后半部分使用全连接层。在网络中还使用了 Dropout 策略，通过随机失活部分层的神经元，避免网络过拟合现象。因为 AlexNet 在 ImageNet 数据集上进行预训练的分类任务为分类大量类别图像，而损伤检测只包含 2 个类别(损伤和未损伤)，所以本文将输出向量修改为只有 2 个类，即输出层采用了分类数设置为 2 类的 Softmax 激活函数。

2.3.2. VGG 模型

VGG 网络最早由 Visual Geometry Group 提出，网络也是沿用该团队名称，该模型在 ImageNet 中实现了 92.7% 的 top-5 测试准确率[14]。卷积神经网络的深度与模型性能关系是 VGG 网络主要研究的对象。它的特点是结构简洁。在这个模型中，它的目标不是有更多的超参数，而是反复堆叠具有步幅为 1 的 3×3 滤波器的卷积层和步幅 2 的 2×2 滤波器的最大池层。VGG16 是单向多层结构，其名称中的 16 代表网络层数，它大约含有 1.38 亿个参数。此外，在本研究中使用 pytorch 搭建 VGG16 预训练版本，在 ImageNet 上训练的模型分类数目是 1000，针对于本文所研究的损伤检测任务，将输出分类改为两类。

2.3.3. ResNet 模型

ResNet 是 2015 年的 ImageNet 大规模视觉识别竞赛中最引人注目的项目，由前微软研究院的何凯明等 4 人共同合作研究的一种新型卷积神经网络[15]。自从 VGG 提出之后，研究者们就开始相信只要提高网络深度就可以直接简单地增加预测精度，但是现实实验结果并非如此，越是深层的卷积神经网络，其模型参数会指数级增长，导致网络优化困难并且会出现梯度消失问题。而 ResNet 的设计概念改变了深度学习的发展方向，该网络通过提出跳跃连接的方式来缓解上述问题，跳跃连接应用于网络内部的残差块中，使得参数易于优化，最终提高了网络的性能。图 3 即为残差块，其中 x 表示输入，残差块的输出就

是 $F(x) + G(x)$ 而不是传统网络层的 $F(x)$ 。当输入和输出的维数是相同的时候，函数 $G(x)$ 的取值就是 x 本身，此时跳跃连接称为恒等映射。因为恒等映射剔除了中间层的权重，所以可以更加容易的训练网络。

现在已经有许多版本的 ResNetXX 架构，其中“XX”表示层数。在 ResNet34 中，网络层数是 34。默认情况下，预训练的模型分类输出类别是表中显示的 1000，但在本文执行的实验分类数目是 2 类，所以前两个网络模型处理方式相同，将最后的 softmax 分类层改成 2。

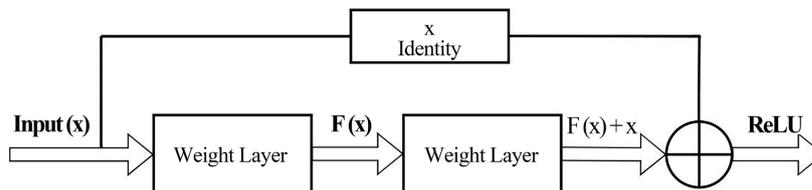


Figure 3. Residual block image
图 3. 残差块示意图

3. 实验与结果分析

3.1. 实验环境

本文的实验都是在具有以下环境配置的设备上进行的：处理器为 12th Gen Intel (R) Core (TM) i7-12700H 2.30 GHz，内存 16 GB；显卡是 NVIDIA GeForce RTX 3060。编译工具 Pycharm，采用 python3.8 编译语言。

3.2. 实验评价标准

实验评价标准为测试集中模型预测的精确度(Accuracy)，计算公式(1)：

$$\text{Accuracy} = \frac{TP}{NUM} \quad (1)$$

其中， TP 指的是预测正确的样本数， NUM 则指的是测试集总共的样本数。

3.3. 模型训练

实验中 batchsize 设置为 64，训练 20 个 epoch，输入图片大小是 224*224。训练过程中优化参数的优化器为 Adam 优化器，该优化器初始学习率设置为 0.00001。选择使用交叉熵损失函数，它可以写成公式(2)的形式：

$$L = \frac{1}{N} \sum_k -[\gamma_k \log(p_k) + (1 - \gamma_k) \cdot \log(1 - p_k)] \quad (2)$$

其中， N 是图像数目， γ_k 表示样本 k 的标签， p_k 表示样本 k 预测为正类的概率。

实验一共 1205 张图片，训练集、验证集和测试集将按照数据集 6:2:2 进行划分，其中使用增强后的 870 张用于模型训练，288 张用于模型验证和未增强的 47 张用于模型测试。实验中根据验证集结果保存网络分类性能最好的权重参数，然后使用与训练样本不同的测试集评估模型的性能，将不同网络模型的测试集结果收集起来进行对比实验。

3.4. 结果及数据分析

3.4.1. 测试集结果比较

本文使用了 AlexNet、VGG16 和 ResNet34 三个模型进行对比实验，测试结果根据上文提及的实验评

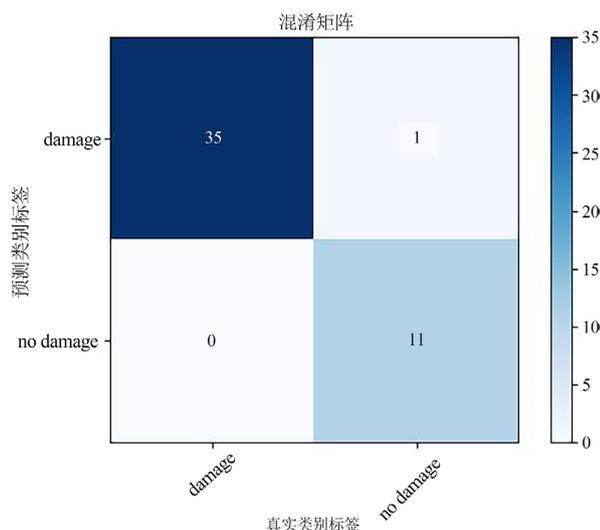
价标准的计算公式,可以得到模型的测试精确度。精确度是指在测试集所有图像中正确分类的图像的数量,3个模型的实验结果如表1所示。

Table 1. The experimental results of the test set
表 1. 测试集实验结果

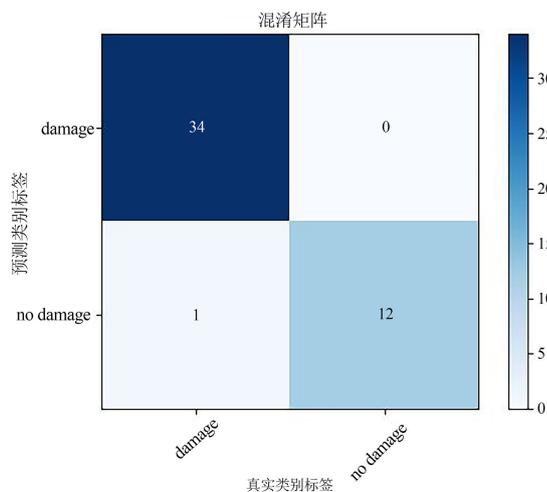
编号	网络结构	Accuracy (%)
1	AlexNet	97.87
2	VGG16	97.87
3	ResNet34	87.23

通过表1可以看出,3个网络模型的验证精度都是非常的高,基本都在80%以上,其中提出时间较早的 AlexNet 和 VGG16 网络精度都达到了 97.87%,而之后提出的网络模型 ResNet34 的测试精度只有 87.23%,这表明了越先进的神经网络并不一定适用于复合材料层合板无损检测领域。

为了进一步比较网络的性能,将三个模型的混淆矩阵绘画出来。如图4所示:



(a) AlexNet 网络



(b) VGG16 网络

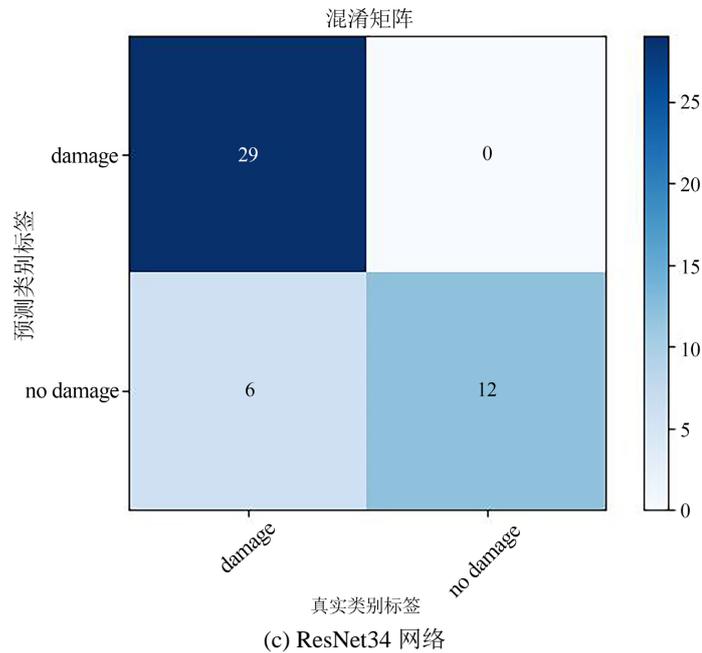
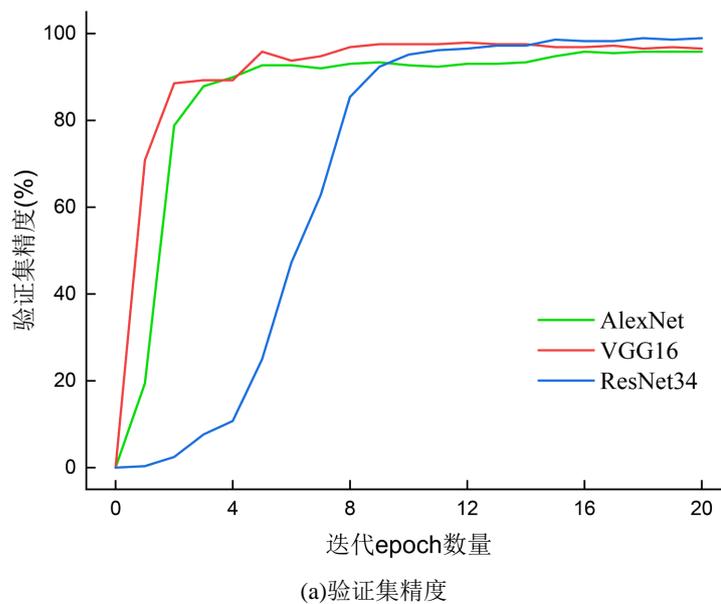


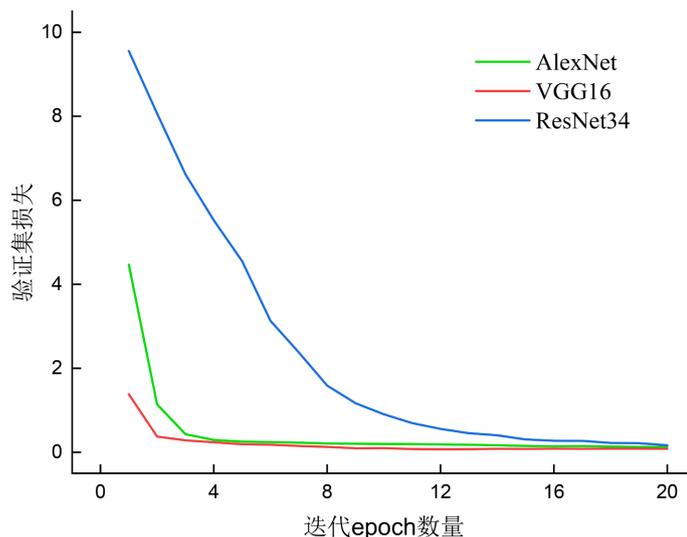
Figure 4. Confusion matrix diagram for different networks
图 4. 不同网络的混淆矩阵图

从图 4 的混淆矩阵图可以看出，虽然 AlexNet 和 VGG 模型的测试集分类准确率相同，但是分类错误的情况不一样，AlexNet 是误将无损伤的图像分类成了损伤图像，而 VGG 模型是将损伤的图像错误分类成了无损伤图像，在现实应用场景中的这个现象会导致巨大的事故，造成无法挽回的经济损失。因此结合混淆矩阵图可以得出最适合与复合材料层合板无损检测的神经网络模型为 AlexNet。

3.4.2. 训练过程分析

为了进一步验证上文得出的实验结论的正确性，将三个不同模型的验证过程中的精度和损失的详细图绘制成图 5 所示：





(b)验证集损失

Figure 5. Iteration curves of each model**图 5.** 各模型迭代曲线

从图 5 中可以清晰的观察到三个模型的验证精度和损失值大小。其中 AlexNet 最大验证精度为 95.83%；VGG16 最大的验证精度为 97.92%；ResNet34 网络最大验证精度为 98.95%。三个网络模型的验证精度相差范围不大。从模型验证损失可以看出 ResNet34 网络相较于前两个网络损失始终更大，这也说明了 ResNet34 网络并不太适用于复合材料层合板无损检测。虽然在模型验证损失 AlexNet 与 VGG16 模型的差异较小，但是 AlexNet 训练验证 20 个 epoch 所花费的时间为 66 秒，而 VGG 整个训练过程需要 4431 秒。因此，从时间方面来看，AlexNet 训练时间少，从而消耗更少资源，更符合现实应用场景的需求。

4. 结论

本文采用深度学习技术对复合材料层合板进行损伤检测。根据网络和相关文献中的复合材料层合板图像构造数据集，并且使用几种不同的数据增强技术扩大了数据集的规模。在实验中比较了预训练后的 AlexNet、VGG16 和 ResNet34 三种不同模型在测试准确率以及训练模型的时间方面的性能。根据实验结果分析可以得出结论，AlexNet 适用于对复合材料层合板图像进行分类，因为与其他模型相比，该模型训练所花费的时间最少且测试精度能够保持在较高水准。本文提出的基于深度学习的复合材料层合板损伤检测模型，可以为复合材料层合板检测提供一种新的检测技术。

基金项目

国家自然科学基金(62366033)；南昌航空大学重点科研基地开发基金(EW202107216)。

参考文献

- [1] Abramovich, H. (2017) Introduction to Composite Materials. Woodhead Publishing, England, 1-47. <https://doi.org/10.1016/B978-0-08-100410-4.00001-6>
- [2] Fernandes, H., Zhang, H., Quirin, S., et al. (2022) Infrared Thermographic Inspection of 3D Hybrid Aluminium-CFRP Composite Using Different Spectral Bands and New Unsupervised Probabilistic Low-Rank Component Factorization Model. *NDT & E International*, **125**, Article ID: 102561. <https://doi.org/10.1016/j.ndteint.2021.102561>
- [3] Fotouhi, M. and Ahmadi Najafabadi, M. (2014) Investigation of the Mixed-Mode Delamination in Polymer-Matrix

- Composites Using Acoustic Emission Technique. *Journal of Reinforced Plastics and Composites*, **33**, 1767-1782. <https://doi.org/10.1177/0731684414544391>
- [4] Gholizadeh, S. (2016) A Review of Non-Destructive Testing Methods of Composite Materials. *Procedia Structural Integrity*, **1**, 50-57. <https://doi.org/10.1016/j.prostr.2016.02.008>
- [5] Jenssen, R. and Roverso, D. (2018) Automatic Autonomous Vision-Based Power Line Inspection: A Review of Current Status and the Potential Role of Deep Learning. *International Journal of Electrical Power & Energy Systems*, **99**, 107-120. <https://doi.org/10.1016/j.ijepes.2017.12.016>
- [6] Ma, A.M., Yu, B.J., Fan, C.W., *et al.* (2022) Damage Detection of Carbon Fiber Reinforced Polymer Composite Materials Based on One-Dimensional Multi-Scale Residual Convolution Neural Network. *Review of Scientific Instruments*, **93**, Article ID: 034701. <https://doi.org/10.1063/5.0076826>
- [7] Ravandi, M., Teo, W.S., Tran, L.Q.N., *et al.* (2017) Low Velocity Impact Performance of Stitched Flax/Epoxy Composite Laminates. *Composites Part B: Engineering*, **117**, 89-100. <https://doi.org/10.1016/j.compositesb.2017.02.003>
- [8] Fu, H., Feng, X., Liu, J., *et al.* (2020) An Investigation on Anti-Impact and Penetration Performance of Basalt Fiber Composites with Different Weave and Lay-up Modes. *Defence Technology*, **16**, 787-801. <https://doi.org/10.1016/j.dt.2019.09.005>
- [9] Shohag, M.A.S., Hammel, E.C., Olawale, D.O., *et al.* (2017) Damage Mitigation Techniques in Wind Turbine Blades: A Review. *Wind Engineering*, **41**, 185-210. <https://doi.org/10.1177/0309524X17706862>
- [10] Fotouhi, S., Pashmforoush, F., Bodaghi, M., *et al.* (2021) Autonomous Damage Recognition in Visual Inspection of Laminated Composite Structures Using Deep Learning. *Composite Structures*, **268**, Article ID: 113960. <https://doi.org/10.1016/j.compstruct.2021.113960>
- [11] Tang, E., Wang, J., Han, Y., *et al.* (2019) Microscopic Damage Modes and Physical Mechanisms of CFRP Laminates Impacted by Ice Projectile at High Velocity. *Journal of Materials Research and Technology*, **8**, 5671-5686. <https://doi.org/10.1016/j.jmrt.2019.09.035>
- [12] Wang, Z., Yang, J., Jiang, H., *et al.* (2020) CNN training with Twenty Samples for Crack Detection via Data Augmentation. *Sensors*, **20**, Article 4849. <https://doi.org/10.3390/s20174849>
- [13] Zhao, X.Y., Dong, C.Y., Zhou, P., *et al.* (2019) Detecting Surface Defects of Wind Turbine Blades Using an Alexnet Deep Learning Algorithm. *Transactions on Fundamentals of Electronics, Communications and Computer Sciences*, **102**, 1817-1824. <https://doi.org/10.1587/transfun.E102.A.1817>
- [14] Theckedath, D. and Sedamkar, R.R. (2020) Detecting Affect States Using VGG16, ResNet50 and SE-ResNet50 Networks. *Sncomputer Science*, **1**, Article No. 79. <https://doi.org/10.1007/s42979-020-0114-9>
- [15] Mahajan, A. and Chaudhary, S. (2019) Categorical Image Classification Based on Representational Deep Network (RESNET). 2019 *3rd International Conference on Electronics, Communication and Aerospace Technology (ICECA)*, Coimbatore, 12-14 June 2019, 327-330. <https://doi.org/10.1109/ICECA.2019.8822133>