

引文格式: 武湛君, 董珊珊, 李建乐, 等. 基于分布式光纤传感与 U-Net 网络的复合材料分层损伤定量识别方法[J]. 航空制造技术, 2024, 67(13): 20-27.

WU Zhanjun, DONG Shanshan, LI Jianle, et al. Quantitative identification method of composite material delamination damage based on distributed optical fiber sensing and U-Net network[J]. Aeronautical Manufacturing Technology, 2024, 67(13): 20-27.

基于分布式光纤传感与 U-Net 网络的 复合材料分层损伤定量识别方法*

武湛君¹, 董珊珊², 李建乐², 朱明睿², 张仕承², 刘海涛², 孙亮², 李汉克², 董孜勋², 徐浩¹

(1. 大连理工大学材料科学与工程学院, 大连 116024;

2. 大连理工大学力学与航空航天学院, 大连 116024)

[摘要] 结构健康监测 (SHM) 是确保飞行器复合材料结构安全性和完整性的重要手段。基于背向瑞利散射的分布式光纤传感器可以通过测量高密度的应变分布为复合材料损伤监测提供数据支持。然而, 结构应变分布特征和损伤的映射关系较为复杂, 无法直接根据应变分布准确判定损伤的定量信息。另外, 分布式光纤传感器数据量大, 通过人为分析应变数据识别损伤较为耗时且准确性偏低。为了应对这一挑战, 提出了一种基于分布式光纤传感数据与 U-Net 神经网络的智能损伤识别方法, 旨在自动精确识别复合材料中常见的分层损伤。首先, 通过有限元仿真构建 U-Net 神经网络的训练集与验证集; 随后进行含分层损伤复合材料板的悬臂加载试验, 通过分布式光纤传感器采集结构应变分布数据作为测试集。损伤识别结果表明, U-Net 神经网络可以对分层损伤的位置、尺寸与形状进行较为精确的定量识别。
关键词: 结构健康监测 (SHM); 复合材料结构; 分布式光纤传感器; 深度学习; U-Net 神经网络

DOI: 10.16080/j.issn1671-833x.2024.13.020



武湛君

教授, 博士生导师, 研究方向为结构健康监测与飞行器结构 / 材料性能表征。

复合材料因高比强度和比刚度广泛应用于各种航空航天结构^[1]。然而航空航天结构的服役环境严苛, 在结构服役过程中容易产生结构损伤, 威胁结构的安全运行。分层损伤是复合材料结构中最常见的损伤形式之一^[2], 损伤发生在结构内部, 会给损伤检测带来困难。结构健康监测 (Structural health monitoring, SHM) 基于先进传感器网络, 在损伤在线识别、结构状态感知与安全评估等领域发挥至关重要的作用。光纤传感器具有体积小、质量轻、抗电磁干扰和耐久性强等诸多优点, 因此广泛应用于各类航空航天结构的健康监测任务中^[1,3]。而分布式光纤传感器 (Distributed fiber optic sensor, DFOS) 测点密度高, 在结构应变分

布监测及损伤定量识别方面具有较强的应用前景。单一男^[4]通过分布式光纤传感器组成应变监测网络对绝热泡沫胶接铝合金板的脱粘和翼梢小翼的接缝凹坑进行了损伤监测, 验证了利用高密度应变信息识别结构损伤方法的有效性。钟照振等^[5]构建了基于高空间分辨率分布式光纤传感器的冲击监测系统, 将监测到的复合材料层合板结构应变响应幅值作为特征量实现了冲击位置辨识, 得到了约 8.44 mm 的平均定位误差。孙晓明等^[6]开发了一套基于光纤传感探测的直升机修理异常振动源定位系统, 通过直升机的振动源动态监控, 识别了直升机的主要振动源。Klute 等^[7]将分布式光纤传感器网络埋入到碳纤维复合材料压力容器

* 基金项目: 国家自然科学基金 (12072056)。

中,测量不同压力水平下的层间应变水平,通过冲击造成的残余应变识别出损伤缺陷的大致位置。Tan 等^[8]利用分布式光纤传感器测得的应变数据对三维变形薄壁金属平板试件进行了屈曲检测和三维变形重建。

近年来,在传感器技术、数据处理和高性能计算的共同推动下,SHM 从传统基于模型的方法逐步发展到数据驱动的方法。通过适当的训练和优化技术,深度学习可以从大量的数据中自动提取与结构损伤相关的特征^[9-10]。将光纤传感技术与人工智能(Artificial intelligence, AI)技术结合,基于结构的应变信息识别结构中存在的损伤是目前 SHM 领域的研究热点。Loutas 等^[11-12]使用 4 根光纤布拉格光栅(Fiber Bragg grating, FBG)传感器来采集碳纤维复合材料加筋板结构动态应变数据,通过在结构不同区域改变质量模拟结构损伤,并使用支持向量机(Support vector machine, SVM)模式识别方法和人工神经网络(Artificial neural network, ANN)识别到了损伤位置。Karypidis 等^[13]采用深度自编码器(Deep autoencoder, DAE)构建了一个异常检测系统,用于监测钢筋混凝土结构的健康状态,研究中采用了分布式光纤传感器,通过应变测量检测结构裂纹,并结合深度自编码器算法 DAE 分析数据;该试验表明,DAE 能够成功量化由横向裂纹导致的损伤,为早期检测裂纹位置、钢筋腐蚀及其他类型损伤提供了新途径。Song 等^[14]提出了一种基于布里渊散射的分布式光纤传感器检测结构微裂纹的深度学习方法,网络架构由 21 层的卷积神经网络构成,使用一根 15 m 长的含人工缺陷宽翼缘钢梁进行方法验证,结果表明该方法能够从应变分布中提取出微裂纹特征,并能从噪声中区分裂纹诱发的局部峰值,能够检测到小至 23 μm 的裂纹。与传统支持向量机和

多层感知器(Multilayer perceptron, MLP)相比,这种基于深度学习的方法表现出更优越的性能。Zhuang 等^[15]在头盔中嵌入光纤布拉格光栅传感器来捕捉撞击时头盔的变形和受力情况,使用了 5 种独立的机器学习(Machine learning, ML)模型及 2 种集成 ML 模型,包括支持向量机、高斯过程回归(Gaussian process regression, GPR)、随机森林(Random forest, RF)、基于 K 近邻实例的学习器(Instance-based K , IBK)、弹性网络回归(Elastic net regression, ENR)、投票(Voting)和加性回归随机森林(Additive regression-random forest, AR-RF);基于 FBG 传感器监测到的应变变化,经过训练的 ML 模型能够准确预测冲击类型,以及冲击力的大小和方向。Liu 等^[16]开发了一个使用分布式光纤传感器和深度学习技术监测结构中裂缝的方法,使用改进的 YOLO 模型识别和定位到了空间分布裂缝。

现有基于光纤信号的机器学习方法,大多仅能识别结构损伤的位置、类型等信息,关于进一步获取损伤的二维尺寸、形状等定量信息的研究较少。图像分割方法为损伤定量信息识别提供了新的思路。目前较为常用的图像分割模型包括 FCN、Segnet、U-Net 等,其中, U-Net 网络融合并扩展了 FCN 和 Segnet 在全卷积网络方面的创新,将跳跃连接贯穿整个网络结构,通过其独特的结构优化了图像分割的性能。U-Net 网络最初由 Ronneberger 等^[17]在 2015 年提出,初衷是为了解决医学图像分割的问题,因其网络结构酷似“U”形而得名。

鉴于 U-Net 神经网络在医学图像处理领域中表现出的优异性能,本文将其与分布式光纤传感技术相结合用于碳纤维层合板分层损伤的定量识别。首先,本文基于有限元模拟的应变数据训练 U-Net 网络,随后通过使用密集布设的分布式光纤传感

器测量得到碳纤维复材板的表面应变数据,将测得的应变数据输入到训练后的 U-Net 网络中,具有像素级识别精度的 U-Net 神经网络对每个数据点进行分类,进而实现对复合材料分层损伤的定量识别。

1 分布式光纤传感与 U-Net 神经网络

1.1 基于背向瑞利散射的分布式光纤应变传感原理

分布式光纤传感器能够把沿光纤长度上的任何点当作测点进行物理场变化的监测,具有连续高密度测量的优点。本文使用的是基于背向瑞利散射的分布式光纤传感器。对于每根光纤,都有与之对应的背向瑞利散射光信号作为其固有信息,这种信号在光纤状态不变时保持稳定。当光纤在某位置经历变形或温度发生改变时,该处的背向瑞利散射光信号的波长会相应地出现变化。通过比较光纤改变前后的背向瑞利散射光信息,就能够定位到光纤状态改变的位置^[4]。

在光纤测量起始阶段首先需要保存一个基准状态的瑞利散射信号,因为光纤局部应变和温度的变化会造成背向瑞利散射光反射光谱的局部漂移,用应变 ε 和温度 T 的函数来表示光谱的漂移,可以测量出光纤局部的应变或温度变化,得到

$$\frac{\Delta\lambda}{\lambda} = -\frac{\Delta\nu}{\nu} = K_T\Delta T + K_\varepsilon\varepsilon \quad (1)$$

式中, λ 为平均光波波长; ν 为频率; $\Delta\lambda$ 为波长偏移量; $\Delta\nu$ 为频率变化量; K_T 和 K_ε 分别是温度和应变的常数系数。

如果忽略温度变化,应变可以写为

$$\varepsilon = -\frac{\bar{\lambda}}{cK_\varepsilon}\Delta\nu \quad (2)$$

式中, c 为光在真空状态下的传播速度; $\bar{\lambda}$ 为光纤解调仪扫描时的中心波长。从式(2)可以看出,通过对比当

前测量时的光纤与基准状态时的光谱偏移,就可以得出应变的测量值。

1.2 U-Net 网络模型

最初的网络是基于 512×512 大小的图像^[17],本文中输入的是 160×80 的应变场数值矩阵,通过对矩阵进行填充,确保经过卷积层后特征矩阵的大小不变,模型中特征矩阵的缩小使用池化层来实现。若采用上述方法,在特征提取部分和上采样对应部分的特征矩阵大小完全一致,在做特征融合时较为便利。本文所采用的 U-Net 网络结构如图 1 所示。该网络由捕捉图像特征的收缩路径和提供定位的对称扩展路径组成。该结构共 5 层,每层包含一对收缩(下采样)路径和扩展(上采样)路径。在收缩路径中,每层使用零填充执行两个 3×3 卷积运算,保持矩阵的原始大小不变。每个卷积运算后面都有一个校正线性单元 ReLU。在第一层中,卷积运算将 3 通道的二维数值矩阵生成 64 个特征通道;在其余层中,特征通道的数量是上一层的两倍。从上一层到下一层,通过 2×2 最大池化操作以 2 的步长对特征通道进行下采样。在最后一步中,总共有 1024 个 10×5 大小的特征二维矩阵。在扩展路径中,每一层特征矩阵的大小都会加倍,同时使用 2×2 反卷积运算,反卷积层通过设置 $\text{stride}=2$ 参数放大特征矩阵,放大后的特征矩阵大小为原来的 2 倍,同时将特征通道数量减半。在每层上采样的开始,来自收缩路径的输出特征通道与对应相同层的扩展路径的特征通道叠加。叠加之后使用零填充执行两个 3×3 卷积运算以保持原始矩阵大小。在最后一层,使用 1×1 卷积运算将 64 个特征通道映射到期望数量的类,与论文中最后输出的通道为 2 不同,由于处理的是 3 分类问题,所以模型最后输出的通道为 3,每个通道对应一个类别的预测分数(Logits)。

2 数据集获取

本文所使用的神经网络架构 U-Net 是从计算机视觉图像分割领域引入的,一般用于图像数据的语义分割,在图像分割领域,研究人员为了获得更大的数据集通常采用对现有图像数据进行平移、旋转、翻转、裁剪等数据增强策略。考虑到结构损伤会引起应变重分布,不同大小的分层损伤在碳纤维层合板中不同位置引起的应变变化,不仅表现为图片上的位置平移和尺寸的放大缩小,应变场的变化也会更为复杂,在本文中不采用图像学中的数据扩充方式,而是通过有限元模拟来获取大量数据。以有限元仿真模拟得到的应变数据作为 U-Net 网络模型的训练集和验证集,再利用分布式光纤传感器测得的真实试件的应变数据作为 U-Net 网络的测试集。

2.1 碳纤维复材板分层损伤有限元模拟

利用 ABAQUS 有限元软件,在复合材料板表面提取与光纤测量路径相对应的应变分布。通过参数化脚本,自动完成模型创建、损伤设置及光纤路径应变提取。针对 100 个

不同分层损伤形状模型施加 10 种载荷,总共得到了 1000 组数据。

复合材料板尺寸为 $100 \text{ mm} \times 200 \text{ mm}$,单层厚度为 0.1 mm ,共 30 层,应用实体单元建模。复合材料采用正交铺层,属性如表 1 所示(E 为不同方向的弹性模量; μ 为泊松比; G 为剪切模量)。分层损伤通过复制节点的方式引入,即在同一个空间位置处存在 2 个节点,分别隶属于上下两层单元。分层位置在距离上表面 0.2 mm 与 0.3 mm 处,即在 2~3 层或 3~4 层之间设置损伤。损伤形状为随机四边形,图 2 所示为 100 个损伤形状里随机抽取的损伤形状,损伤大小设置在 $400 \sim 410 \text{ mm}^2$ 范围内,加载方式设置为悬臂弯曲。板左端固支,右端采用面外位移加载,最小为 5 mm ,最大为 50 mm ,间隔 5 mm 。

针对图 2 中的损伤,有限元模拟的应变分布结果如图 3 所示,可以看到分层损伤位置的应变分布发生一定扰动,但应变分布特征与损伤区域并不存在精确对应的关系。

将从 ABAQUS 导出的光纤路径上的表面节点应变 ϵ^{sim} 通过插值拟合的方式得到 80×160 的全场应变 $\epsilon_{\text{D}}^{\text{sim}}$,处理过程如图 4 所示,然后把应变场




图 1 U-Net 网络结构

Fig.1 U-Net network architecture

表 1 材料属性

Table 1 Material properties

E_1/GPa	E_2/GPa	E_3/GPa	μ_{12}	μ_{13}	μ_{23}	G_{12}/GPa	G_{13}/GPa	G_{23}/GPa
144	9.3	9.3	0.312	0.312	0.32	4.68	4.68	4

数据 ε_{2D}^{sim} 复制成 $80 \times 160 \times 3$ 的三维数值矩阵作为模型的训练数据集。

2.2 基于密集布设分布式光纤传感网络的碳纤维复材板应变数据采集

2.2.1 预埋分层损伤的碳纤维复材板试件制作

试验试件大小为 $200 \text{ mm} \times 100 \text{ mm}$, 厚度为 12 层, 采用 T700 单向预浸料进行正交铺设, 通过在 2~3 层碳纤维之间添加 $20 \text{ mm} \times 20 \text{ mm}$ 的正方形脱模布设置分层损伤, 损伤位置如图 5 所示。碳纤维复材板试件固化工艺流程为: 首先将试件加热至 $100 \text{ }^\circ\text{C}$ 并保温 1 h, 完成预固化处理; 随后将温度升至 $130 \text{ }^\circ\text{C}$ 固化 2 h; 最后将温度升至 $160 \text{ }^\circ\text{C}$ 固化 2 h。整个固化过程中试件在抽真空条件下施加压力, 以确保树脂的充分渗透和空气的排除。

2.2.2 高密度光纤布设

为了得到准确可靠的复材板表面应变场, 将分布式光纤传感器进行高密度布设。考虑到试验过程中夹具和光纤弯折对测量信号的影响, 只对试件的局部区域进行光纤布设, 光纤监测范围为 $80 \text{ mm} \times 80 \text{ mm}$ 区间, 光纤相邻间隔为 5 mm , 采用螺旋方式布设光纤。光纤布设路径设计如图 6 (a) 所示, 共 17 条光纤测量段,




图 2 损伤形状

Fig.2 Damage shape



图 3 沿光纤方向的表面应变场云图

Fig.3 Cloud map of surface strain field along the fiber optic direction

其中有 5 条(第 2、4、6、8、10 测量段)通过损伤区域; 3 条(第 4、6、8 测量段)通过损伤区域的内部, 2 条(第 2、10 测量段)位于损伤区域的边界。光纤布设完成后的复材板试件如图

6 (b) 所示。

需要指出的是, 图 6 中采用光纤的二维致密布设, 让光纤尽可能覆盖结构表面, 这使得光纤在垂直测量路径方向也需要采用高密度布设, 可能

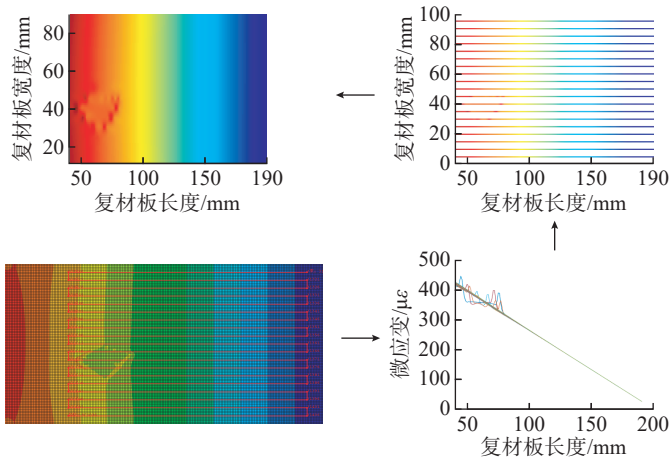


图 4 复合材料层合板多路径密集应变提取与二维插值结果

Fig.4 Multi-path dense strain extraction and two-dimensional interpolation results in composite laminate






图 5 分层损伤设计

Fig.5 Layered damage design



(a) 光纤路径设计图



(b) 复材板试件

图 6 复材板试验件及光纤路径

Fig.6 Composite board test piece and optical fiber path

带来工程适用性的问题。实际应用中,需要根据检测损伤大小(如分层尺寸、裂纹长度等)设定布设密度。另外,实际工程中可以在需要重点监测的关键局部区域(如应力集中区域、螺孔周边等)进行二维致密布设,而在非关键区域采用稀疏布设,只测量一维高密度应变。

2.2.3 应变采集

采用悬臂弯曲加载,试件一端固支,另一端采用悬挂砝码的方式进行加载,如图7所示。试验所采用的应变采集装置是LUNA公司的ODISI分布式光纤采集系统,测量时光纤路径上的应变测点间距设置为1 mm,传感器标距为7 mm。设备连接调试好后再在无载荷状态下采集光纤基准信号,试验包含4个载荷等级:载荷步1,载荷大小5 N;载荷步2,载荷大小10 N;载荷步3,载荷大小15 N;载荷步4,载荷大小20 N。

2.2.4 光纤应变数据分析处理

鉴于试验所测得的4个载荷步的应变数据呈线性变化,文中只给出最大载荷下的应变曲线,如图8所示,为20 N载荷下光纤实测的复材板表面应变数据 $\epsilon^{\text{measured}}$ 曲线,可以明显看出应变数据呈循环变化的趋势,这与光纤的环绕布设方式相符。应变曲线中极小值点的应变数值小于0,原因是该位置对应光纤弯折路径区域中点。由于悬臂加载下复材板表面单向受拉,横向根据泊松关系收缩,故存在应变负值。此外,光纤弯折处的应变分布较复杂,容易带来误差,因此在应变分析时忽略此区域。在监测区域的应变数据中可以看出由于分层损伤造成的应变扰动现象,通过试验测得的分层损伤应变特征与有限元模拟基本一致。在损伤边界处的应变扰动特征不如损伤内部明显。

将光纤采集到的一维应变数据 $\epsilon^{\text{measured}}$ 根据光纤布设路径映射到二维平面中对应位置,同时采用插值拟合的方式将应变数据插值




图7 试验加载装置及设备
Fig.7 Experimental loading device and equipment




图9 复合材料层合板多路径密集应变测量与二维插值结果
Fig.9 Multi-path dense strain measurement and two-dimensional interpolation results in composite laminate

为1 mm间隔的80×80的应变场数值矩阵 $\epsilon_{2D}^{\text{measured}}$,处理过程如图9所示,然后把应变场数据 $\epsilon_{2D}^{\text{measured}}$ 复制成3×80×80的三维数值矩阵保存为.npy文件作为模型的输入数据。

2.2.5 U-Net网络的训练和验证试验

为了评估本文所提方法的有效性,搭建了神经网络训练平台训练U-Net网络并进行验证。

(1) U-Net网络训练平台搭建。

碳纤维复材板分层损伤识别U-Net网络训练平台主要硬件配置为:CPU, AMD Ryzen Threadripper PRO 3955WX 16-Cores; GPU, NVIDIA GeForce RTX 3090; 内存为32 G。

相比传统算法,神经网络模型结构更复杂,为了高效、便捷、灵活地实现网络模型搭建,需要借助高质量的深度学习框架,Pytorch和Tensorflow是目前最主流的两个现代化深度学习框架,极大地提高了神经网络搭建的效率。本文所使用的软件环境如表2所示。




图8 光纤实测应变曲线
Fig.8 Fiber optic measured strain curve




表2 主要软件环境及其对应的版本号
Table 2 Main software environments and their corresponding version numbers

软件平台	版本号
操作系统	Linux
深度学习框架	Pytorch 2.0.1
集成平台	Conda 4.8.3
编译语言	Python 3.8.3
GPU 运算平台	CUDA 11.6

(2) 损失函数。

U-Net网络模型为输入数据的每个数据点输出一个相应的Logits向量,向量的长度为总类别数 C ,向量中的每个元素代表该数据点属于各个类别的原始分数。本文采用经典的交叉熵损失函数CrossEntropyLoss,其计算过程为:首先自动对每个数据点对应的Logits向量应用Softmax函数,将每个数据点的预测(模型输出的每一行)Logits转换为概率分布,其中每个元素的值在0~1之间,且所有元素的和等于1;然后计算每个数

据点的真实类别标签对应的预测概率的负对数,得到单个数据点的交叉熵损失;最后取所有损失的平均值作为损失函数 CrossEntropyLoss 最终的计算结果。

单个数据点的交叉熵损失计算公式为

$$L = -\ln p_c = -\ln \left(\frac{e^{s_c}}{\sum_{j=1}^C e^{s_j}} \right) \quad (3)$$

式中, p_c 为通过 Softmax 函数计算的第 c 个类别的概率; C 是类别的总数; s_j 是模型输出中 j 个类别的 Logit; s_c 是真实类别 c 对应的 Logit。

(3) 评价指标。

为了评估复合材料分层损伤识别的 U-Net 网络模型的训练结果,需要对模型的数据点级识别结果给出评价指标。IoU (Intersection over union) 交并比定义如图 10 所示,用于测量模型的预测区域与实际目标之间的重叠程度,是计算机视觉中一种广泛用于评估神经网络模型识别准确性的指标。本文通过计算 IoU 值对分层损伤识别结果进行定量分析。

IoU 的计算公式为

$$\text{IoU} = \frac{\text{TP}}{\text{FP} + \text{TP} + \text{FN}} \quad (4)$$

式中,真阳性 TP (True positives) 为网络预测损伤与真实损伤的重合部分;假阳性 FP (False positives) 为非损伤区域网络错误判断为损伤的部分;假阴性 FN (False negatives) 为真实损伤区域网络未检测出的部分。

把有限元模拟得到的数据集按照 9:1 划分为训练集和验证集,放入 U-Net 网络进行训练和模型评估,采用 Adam 优化算法,学习率 (Learning rate) 设置为 0.0005,迭代的批量大小 (Batchsize) 设置为 16,网络训练对本集的学习次数 (Epoch) 设置为 500。



图 10 IoU 定义

Fig.10 IoU definition

3 U-Net 网络分层损伤识别结果

训练集的损失曲线和验证集的损失曲线如图 11 和 12 所示。可以看出,损失不断降低并最终趋于平缓,模型训练表现良好。接下来,使用光纤传感器测得的真实复材板的表面应变数据,测试模型对分层损伤的识别效果,网络模型的预测结果如图 13 所示。图 13 为 U-Net 网络对 4 个加载等级下复材板试验件分层损伤的识别结果,红色框为设计的分层损伤所在位置,黄色和蓝绿色区域为网络模型的预测结果;根据网络模型的测试结果可知,本文所提出的深度学习损伤识别方法识别到了应变数据中存在的损伤特征,对分层损

伤的位置和形状有良好的识别准确性,但因为试验中存在一些误差,例如复材板切割尺寸不精准、脱模布裁剪与粘贴偏移、光纤布设路径偏移、光纤标定不够精确、噪声等都会对损伤最终的识别准确性有所影响,造成对部分点的误判,出现损伤边界位置处识别准确度较低的问题。

U-Net 网络对 4 种加载等级下的碳纤维层合板分层损伤的 IoU 计算结果为 0.6374、0.6523、0.6523 和 0.6457,其中最大为 0.6523,最小为 0.6374,平均 IoU 得分为 0.6469。

为了更进一步定量描述损伤识别精度,将预测损伤的面积大小和形心位置作为损伤结果定量表征的判定标准,得到如表 3 所示的误差分析,最大定位误差为 2.0 mm,最大面




图 11 训练集的损失曲线

Fig.11 Loss curve of the training set




图 12 验证集的损失曲线

Fig.12 Loss curve of validation set




图 13 U-Net 网络对损伤的预测结果

Fig.13 Prediction results of U-Net network for damage

表 3 损伤定量化表征误差结果

Table 3 Error of quantitative characterization of damage

加载等级 /N	损伤位置 (x, y) /mm		定位误差 /mm	损伤尺寸 /mm ²		面积误差 /mm ²
	真实	识别		真实	识别	
5	(40, 55)	(41.7, 55.1)	1.7	400	399	1.0
10	(40, 55)	(41.9, 55.2)	1.9	400	400	0
15	(40, 55)	(41.9, 55.3)	1.9	400	400	0
20	(40, 55)	(42.0, 55.3)	2.0	400	395	5.0

积误差为 5.0 mm^2 , 平均定位误差为 1.9 mm , 平均面积误差为 1.5 mm^2 。

4 U-Net 与 FCN 的损伤识别结果对比

为了验证 U-Net 网络相比于其他深度学习模型的优越性, 采用另外一种图像分割网络 FCN 进行了分层损伤识别, 网络结构如图 14 所示。该网络结构中包含卷积层、池化层与反卷积层, 在反卷积过程中将 p5 层的输出进行 2 倍的上采样后与 p4 层的输出进行逐像素相加, 之后进行 2 倍的上采样与 p3 层的输出再次进行逐像素相加, 最后将通过加法获得的特征矩阵进行 4 倍的上采样, 获得与输入同尺寸的输出。FCN 网络数据训练时采用与 U-Net 完全相同的数据集, 所采用的学习率、迭代批量大小、学习次数都保持一致。

50 N 加载下的损伤识别对比结果如图 15 所示, 可以看到, FCN 网络对复合材料分层的识别精度明显低于 U-Net 网络, 分割结果不够精

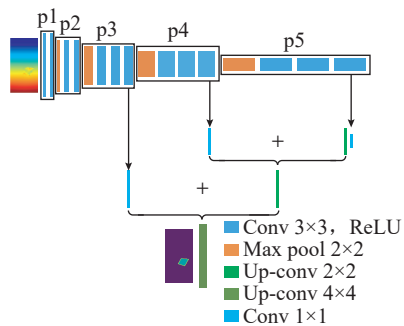


图 14 FCN 网络结构

Fig.14 FCN network structure




图 15 U-Net 网络与 FCN 网络的损伤识别结果对比

Fig.15 Comparison of damage identification results between U-Net and FCN networks

细, 并且在无损区域存在错误的损伤预报。其原因是 FCN 网络结构跳跃连接主要出现在网络的后半部分, 并不像 U-Net 在整个网络中系统地应用; 此外, 与 FCN 的矩阵加法不同, U-Net 网络通过其独特的对称结构和跳跃连接将下采样路径中的每一层输出与上采样路径中相应层级的特征进行通道融合; 通过这种方式, 系统性地融合不同层次的特征, 在图像分割中保持空间信息的完整性。这使得 U-Net 在需要精确边缘细节的分割任务中表现出更优异的性能。

5 结论

本文通过有限元仿真获取 U-Net 神经网络训练所需的大量数据, 降低了通过试验来获取数据的成本, 将分布式光纤传感器测得的含分层损伤复合材料层合板的表面应变数据作为 U-Net 网络的测试集, 通过计算每次 U-Net 网络输出结果的 IoU 来描述 U-Net 网络对复材板分层损伤识别的准确性, 并且引入了损伤预测区域的形心位置和面积大小进一步评估 U-Net 网络对损伤识别的精确性, 通过综合表征手段评价分层损伤的识别效果。

自主编写的参数化建模脚本高效地实现了模型的前后处理和损伤设置, 通过有限元模拟得到的含损伤结构应变分布特征与真实复合材料板的应变分布特征基本一致。U-Net 神经网络模型训练过程中, 训练集的损失曲线和验证集的损伤曲线都很好收敛, 训练后的模型准确识别到了光纤监测数据的分层损伤。在测试集中, 损伤识别结果为平均 IoU 得分 0.6469, 平均定位误差为 1.9 mm , 平均面积误差为 1.5 mm^2 。结果表明, U-Net 神经网络可以对分层损伤的位置、尺寸与形状进行较为精确的定量识别。

本文基于仿真构建的数据集解决了试验数据的稀缺性问题。但仿

真模型在铺层、固化工艺、损伤特征等方面与实际结构存在差异, 可能导致样本库的不适用问题。针对这个问题, 可以采取少量试验数据加大量仿真数据的形式构建数据集, 并结合数据扩充、引入噪音等方式, 加强 U-Net 网络的模型泛化能力。此外, 分布式光纤损伤识别的本质是捕捉 (损伤造成的) 材料局部不连续带来的应变奇异性, 与损伤大小、严重程度、载荷大小和光纤标距等多种因素相关。未来将开展精细的理论与试验研究, 对损伤敏感性、鲁棒性等做深入分析, 并结合机器学习方法对损伤发生具体铺层位置等关键信息进行定量识别。

参考文献

- [1] 龚煜廉, 张建国, 李文博. 光纤传感在航天复材结构健康监测中的应用 [J]. 航天器工程, 2022, 31(5): 60-66.
- [2] GONG Yulian, ZHANG Jianguo, LI Wenbo. Application of optical fiber sensing in health monitoring of aerospace composite structure [J]. Spacecraft Engineering, 2022, 31(5): 60-66.
- [3] 王梓尧. 复合材料分层损伤疲劳扩展监测与预测研究 [D]. 南京: 南京航空航天大学, 2021.
- [4] WANG Ziyao. Research on monitoring and prediction of delamination damage fatigue extension of composite materials [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2021.
- [5] DI S R. Fibre optic sensors for structural health monitoring of aircraft composite structures: Recent advances and applications [J]. Sensors, 2015, 15(8): 18666-18713.
- [6] 单一男. 基于分布式光纤传感的典型结构状态监测研究 [D]. 大连: 大连理工大学, 2020.
- [7] SHAN Yinan. Study of structural states monitoring method for typical structures based on distributed optical fiber sensing [D]. Dalian: Dalian University of Technology, 2020.
- [8] 钟照振, 曾捷, 李艳芬, 等. 复合材料层板 OFDR 分布式光纤冲击判位方法研究 [J]. 振动、测试与诊断, 2023, 43(5): 1005-1010, 1044.
- [9] ZHONG Zhaozhen, ZENG Jie, LI Yanfen,

et al. OFDR distributed optical fiber impact localization method of composite laminate[J]. Journal of Vibration, Measurement & Diagnosis, 2023, 43(5): 1005–1010, 1044.

[6] 孙晓明, 苏世伟, 尹华光, 等. 基于光纤传感探测的直升机修理异常振动源定位研究[J]. 装备环境工程, 2023, 20(5): 128–137.

SUN Xiaoming, SU Shiwei, YIN Huaguang, et al. Location of abnormal vibration source in helicopter repair based on optical fiber sensing detection[J]. Equipment Environmental Engineering, 2023, 20(5): 128–137.

[7] KLUTE S M, METREY D R, GARG N, et al. In-situ structural health monitoring of composite-overwrapped pressure vessels[J]. Sampe Journal, 2016, 52(2): 7–17.

[8] TAN X, GUO P W, ZOU X X, et al. Buckling detection and shape reconstruction using strain distributions measured from a distributed fiber optic sensor[J]. Measurement, 2022, 200: 111625.

[9] AZAD M M, KIM S, BIN CHEON Y, et al. Intelligent structural health monitoring of composite structures using machine learning,

deep learning, and transfer learning: A review[J]. Advanced Composite Materials, 2024, 33(2): 162–188.

[10] AZIMI M, ESLAMLOU A D, PEKCAN G. Data-driven structural health monitoring and damage detection through deep learning: State-of-the-art review[J]. Sensors, 2020, 20(10): 2778.

[11] LOUTAS T H, PANOPOULOU A, ROULIAS D, et al. Intelligent health monitoring of aerospace composite structures based on dynamic strain measurements[J]. Expert Systems With Applications, 2012, 39(9): 8412–8422.

[12] PANOPOULOU A, ROULIAS D, LOUTAS T H, et al. Health monitoring of aerospace structures using fibre Bragg gratings combined with advanced signal processing and pattern recognition techniques[J]. Strain, 2012, 48(3): 267–277.

[13] KARYPIDIS D F, BERROCAL C G, REMPLING R, et al. Structural health monitoring of RC structures using optic fiber strain measurements: A deep learning approach[C]//Proceedings of IABSE Congress.

New York, 2019.

[14] SONG Q S, ZHANG C, TANG G W, et al. Deep learning method for detection of structural microcracks by Brillouin scattering based distributed optical fiber sensors[J]. Smart Materials and Structures, 2020, 29(7): 075008.

[15] ZHUANG Y Y, YANG Q B, HAN T H, et al. Fiber optic sensor embedded smart helmet for real-time impact sensing and analysis through machine learning[J]. Journal of Neuroscience Methods, 2021, 351: 109073.

[16] LIU Y M, BAO Y. Intelligent monitoring of spatially-distributed cracks using distributed fiber optic sensors assisted by deep learning[J]. Measurement, 2023, 220: 113418.

[17] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[C]//Proceedings of International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2015.

通讯作者: 徐浩, 副教授, 博士, 研究方向为结构健康监测和复合材料结构设计。

Quantitative Identification Method of Composite Material Delamination Damage Based on Distributed Optical Fiber Sensing and U-Net Network

WU Zhanjun¹, DONG Shanshan², LI Jianle², ZHU Mingrui², ZHANG Shicheng², LIU Haitao², SUN Liang², LI Hanke², DONG Zimai², XU Hao¹

(1. College of Materials Science and Engineering, Dalian University of Technology, Dalian 116024, China;

2. College of Mechanics and Aerospace Engineering, Dalian University of Technology, Dalian 116024, China)

[ABSTRACT] Structural health monitoring is a crucial approach for ensuring the safety and integrity of composite material structures in aircraft. Distributed fiber optic sensors based on backscattered Rayleigh scattering provide data support for composite material damage monitoring by measuring high-density strain distributions. However, the mapping relationship between structural strain distribution characteristics and damage is complex, making it challenging to accurately determine the quantitative information of damage based solely on strain distribution. Additionally, the large volume of data from distributed fiber optic sensors makes manual analysis of strain data time-consuming and less accurate. To address this challenge, an intelligent damage identification method based on distributed fiber optic sensing data and the U-Net neural network is proposed. It aims to automate the precise identification of common delamination damage in composite materials. Initially, training and validation sets for the U-Net neural network are constructed through finite element simulations. Subsequently, cantilever loading tests of composite material plates with delamination damage are conducted, and structural strain distribution data are collected as a test set using distributed fiber optic sensors. The damage identification results demonstrate that the U-Net neural network can accurately quantify the position, size, and shape of delamination damage.

Keywords: Structural health monitoring (SHM); Composite structures; Distributed fiber optic sensors; Deep learning;

U-Net neural network

(责编 逸飞)