

文章编号: 1001-4888(2024)04-0413-10

基于数字体积相关的应变先验损伤识别方法*

仓娇青¹, 肖宇¹, 苏勇², 王鸿翰¹, 胡小方¹, 许峰¹

(1. 中国科学技术大学 中国科学院材料力学行为和设计重点实验室, 安徽合肥 230026;

2. 安徽医科大学 生物医学工程学院, 安徽合肥 230032)

摘要: 研究材料内部的破坏失效过程, 揭示内部损伤演化机制, 是预防断裂失效的关键。计算机断层扫描技术(Computed tomography, CT)可以进行内部损伤演化过程的三维表征, 为研究材料内部损伤演化机制提供支撑。然而 CT 图像中损伤演化的定量识别提取, 面临着损伤特征弱信号被图像中复杂结构信号湮没的难题。本文提出引入力学参量引导神经网络的思路, 将基于数字体积相关(Digital volume correlation, DVC)获得的三维应变场作为力学参量先验信息, 引导并约束网络训练, 从而实现裂纹的识别提取。通过实际 CT 实验数据定量评价并验证了该方法可以提高微小裂纹识别精确率, 减少识别错误率。

关键词: CT 图像; 数字体积相关; 应变; 内部损伤识别; 神经网络

中图分类号: TP391.41 **文献标识码:** A **DOI:** 10.7520/1001-4888-23-101

0 引言

因为大多断裂失效事故发生突然, 不能提前预知, 并会造成严重的人员伤亡及经济损失^[1], 所以其破坏过程的研究一直是力学领域的重要问题。揭示材料内部的损伤机理, 是提高材料性能、预防失效破坏的关键^[2]。突发的构件材料断裂失效必然起源于其内部损伤演化, 然而内部损伤演化的测量和捕捉一直是实验力学所面临的重要难题。

计算机断层扫描技术(Computed tomography, CT)可以实现内部损伤演化的三维原位观测, 具有无损、三维全场、高分辨测量等优势, 在损伤机理的研究中具有重要的应用^[3-6]。要完成损伤机理的研究, 在损伤演化观测的基础上, 需要进一步进行裂纹形貌、萌生位置、裂纹长度、取向等力学参量的定量识别。一方面, 传统的图像识别方法需要人工干预且主观性较强, 难以适用于原位 CT 实验海量三维数据的处理。另一方面, CT 技术所采集的投影图是物体沿射线方向的积分, 因而对于内部结构复杂的试样, 重建后的断层图中内部微小损伤所对应的弱信号可能被湮没, 导致如图 1 圈中区域所示的微小损伤难以识别和提取。

近年来, 随着神经网络的发展, 其全自动、智能化等特点使其可以在无需人工干预的情况下实现大量数据的自适应处理^[7], 在 CT 图像的识别领域得到了应用^[8-11]。XIAO 等^[8]开发了一种基于卷积神经网络的 CT 图像分割方法, 并结合传统滤波器提取疲劳裂纹的三维形状。MENASCHE 等^[11]将 U-Net 和 FCN 等卷积神经网络应用于 CT 图像中裂纹特征的分割, 以观测结构内的裂纹扩展。然而现有神经网络分割提取方法仅考虑图像层面的灰度或者形状特征, 在原位力学 CT 数据中内部损伤演化弱信号特征被材料本身结构信号所湮没的条件下, 仍然难以获得令人满意的损伤演化识别提取效果。

* 收稿日期: 2023-05-19; 修回日期: 2023-06-09

基金项目: 国家自然科学基金项目(12027901, 12002337)

通信作者: 肖宇(1992-), 男, 博士, 副研究员。主要从事实验固体力学研究。Email: xiaoyuxy@ustc.edu.cn




图 1 CT 图像示例

Fig. 1 Examples of CT images

针对仅考虑图像灰度和结构特征的神经网络难以适用于损伤演化力学特征识别提取的难题,本文采用考虑力学信息约束的思路,提出了基于数字体积相关(Digital volume correlation, DVC)的应变先验损伤识别方法。通过 DVC 方法获取材料不同状态的三维应变场,使用应变引导 U-Net 网络训练,利用力学参量凸显损伤的力学信号,以实现微小损伤的精确识别。将该方法应用于一组实际原位力学 CT 实验数据,并分别通过图像分割评价参数和裂尖坐标力学参量对所提出方法损伤识别结果进行了评价。精确率(Precision)和 F1-score 指标分别提高了约 26% 和 15%,裂尖坐标偏差值降低了约 72%。结果表明,引入力学参量能够有效调整神经网络的注意力权重,提高损伤识别的精确率并减少错误识别。

1 基于 DVC 的应变先验损伤识别方法

材料的内部损伤是一种典型的力学特征,从本质上看,应力是萌生损伤的根本原因。材料内部结构不均匀,导致局部应力集中,进而导致萌生损伤。虽然应力无法直接测量,但应力和应变之间存在本构关系,通过不同状态间的应变可以反映应力分布,从而将应变与损伤萌生演化关联起来^[12]。因此,应变与损伤演化之间的关联可以为内部损伤识别提取提供关键的力学先验信息,提高损伤演化弱信号的识别提取效果。DVC 技术可以基于原位力学 CT 的时序演化结果,定量反演内部全场应变分布^[13-14]。由此,通过引入应变这一力学信息,发展了基于 DVC 的应变先验损伤识别方法。

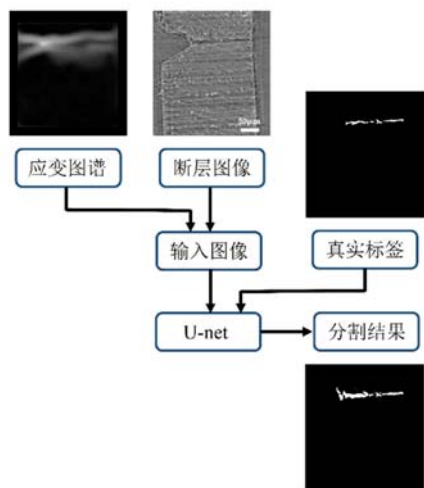


图 2 基于应变先验的裂纹分割算法流程

Fig. 2 Process of crack segmentation method based on strain priori

基于 DVC 的应变先验损伤识别方法主要包括 3 个模块:基于 DVC 的三维应变场提取模块、CT 图像与应变图谱融合模块以及神经网络模块。该方法的具体流程如图 2 所示,首先,获取材料的原位 CT 重建断层图,并通过 DVC 方法得到内部三维应变场;接下来,将三维应变场切割为二维应变图谱,并与对应的 CT 图像融合,作为后续网络的输入图像;最后,利用真实标签,通过卷积神经网络 U-Net 学习损伤的特征,得到损伤分割结果图。

本文使用局部 DVC 算法^[15],通过如下步骤进行三维应变场提取:(1)变形前后体图像的采集与重建。(2)在参考体图像中选择特定大小的子区。(3)在目标体图像中逐像素搜索子区,找到与参考子区相关函数最大的目标子区,由此得到整像素位移,即形函数初值。(4)采用亚像素迭代算法对相关函数进行优化,以实现形函数的迭代更新。(5)依次计算各个子区,从而获得三维位移场。(6)采用差分法或多项式拟合等方法从三维位移场

获取三维应变场。

使用 DVC 方法获取材料的三维应变场后,将三维应变场沿纵向切片,得到二维应变图谱,与 xz 方向 CT 切片图一一对应。图 3 展示了 CT 切片图与应变图谱之间的对应关系,由图可见应变集中可以

反映裂纹的大致区域。为了在神经网络训练过程中同时考虑 CT 切片的灰度分布以及应变图谱中的应变分布,本文采用了通道融合的方法^[16]。CT 图像和二维应变图谱均是单通道灰度图,可以通过在输入端进行通道融合获得三通道图像,从而在网络中引入应变先验信息。通道融合过程中,可以对两者采用不同的权重。对于螺旋叠层复合材料数据集,采用 3 个不同的权重,分别为 1 : 1、1 : 2、2 : 1,经实验验证,当 CT 图像与应变图谱融合比例为 2 : 1 时达到最佳分割效果。




图 3 CT 图像与应变图谱的对应关系

Fig. 3 Correspondence between CT image and strain map

本文使用的卷积神经网络是图像分割中最经典的语义分割模型 U-Net 网络^[17],其网络结构及参数如图 4 所示。图 4 中左半部分是特征提取,即编码器,右半部分是上采样,即解码器,中间部分是传递两者之间信息的长连接部分,即跳跃连接。编码器包含若干下采样模块,每个下采样模块由 2 个 3×3 卷积层(ReLU)和 1 个 2×2 最大池化层组成;解码器包含若干上采样模块,各个上采样模块均由 2×2 的转置卷积层组成,用于上采样;用跳跃连接(长连接)将编码器与解码器的特征图进行特征拼接(通道维度),将编码器每一层提取到的语义信息传递给对应的解码器,以此弥补经过下采样模块时丢失的图像语义信息,再通过 2 个 3×3 卷积层(ReLU)来进一步提取图像特征信息;最后,将特征图输入到 1 个 1×1 卷积层(Sigmoid)中,获得分割概率图。

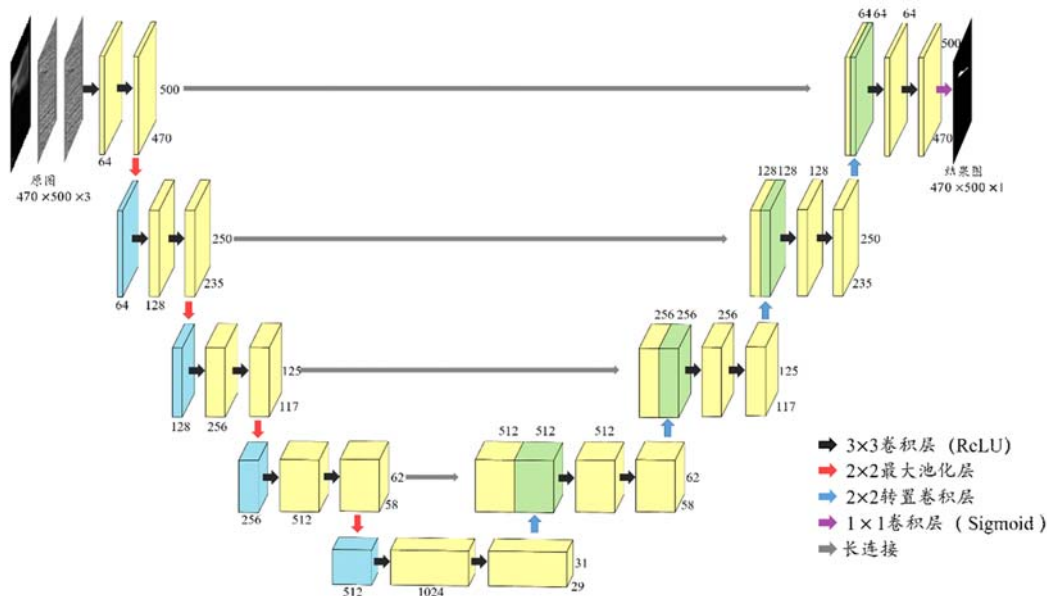


图 4 U-Net 网络结构

Fig. 4 The network structure of U-Net

引入应变先验的 U-Net 网络的学习训练过程可以表示为

$$\hat{y} = f(x_1, x_2) \tag{1}$$

式中： \hat{y} 为网络的预测概率； x_1 为输入的 CT 图像； x_2 为输入的应变图谱； f 为关于 x 和 y 的非线性函数。

学习训练的过程就是通过损失函数不断更新非线性函数 f , 使得网络的预测概率 \hat{y} 接近于真实标签。基于应变先验的学习训练过程示意图如图 5 所示, 将 CT 图像和应变图谱分别作为单独的通道输入, 再对不同通道用不同的卷积核进行特征提取, 得到特征图, 将所有通道特征图相加融合, 得到综合考虑灰度特征和应变特征的融合特征图; 再利用 Softmax 激活函数对融合特征图进行归一化, 得到概率图, 即预测标签; 最后利用损失函数衡量预测标签与真实标签之间的差异, 并进行反向传播, 更新卷积核参数, 直到预测标签接近于真实标签, 停止反向传播, 完成训练。

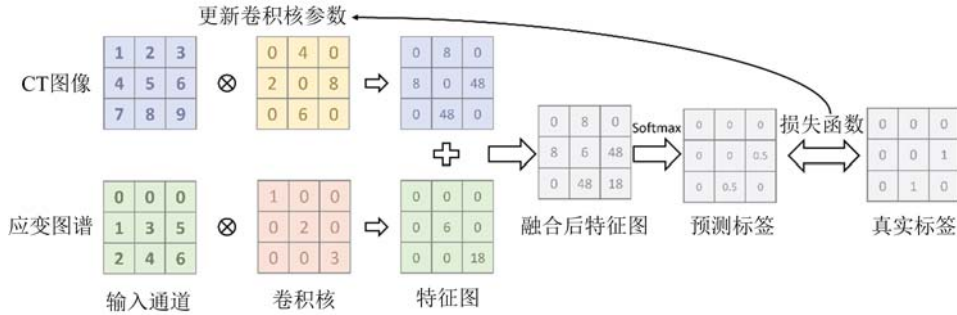


图 5 基于应变先验的学习训练过程示意图

Fig. 5 Schematic diagram of learning training process based on strain priori

在学习训练过程中使用的损失函数是在分割问题中具有代表性的二值交叉熵损失函数(Binary cross-entropy loss, BCE Loss)和 Dice 损失函数(Dice Loss)。交叉熵描述的是 2 个概率分布的差异, 其具体表达式为

$$L_{\text{BCE}} = \frac{1}{N} \sum_{i=1}^N - (y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)) \quad (2)$$

式中: L_{BCE} 为二值交叉熵损失; y_i 和 \hat{y}_i 分别为像素点 i 的真实标签和网络预测标签; N 为像素点总个数。

Dice 损失函数来源于 Dice 系数, 是一种用于衡量 2 个样本之间相似性的指标函数, 其具体表达式为

$$L_{\text{Dice}} = 1 - \frac{2 \sum_{i=1}^N y_i \hat{y}_i}{\sum_{i=1}^N y_i + \sum_{i=1}^N \hat{y}_i} \quad (3)$$

式中: L_{Dice} 为 Dice 损失。

BCE 损失函数虽然在大部分语义分割中效果良好, 但是当正负样本数量严重不平衡时, 该损失函数会导致模型向背景严重倾斜, 由此造成不好的分割效果。Dice 损失函数可以有效改善该问题, 但是由于收敛速度很快, 导致训练过程不稳定, 网络鲁棒性低。因此, 本文采用的损失函数是两者组合的损失函数, 具体表达式为

$$L = aL_{\text{BCE}} + bL_{\text{Dice}} \quad (4)$$

式中: a 和 b 分别为 2 个损失函数的权重, 用来平衡这 2 种损失函数。

采用类激活热力图(Class activation map, CAM)^[18], 可以直观地观测到不同位置的像素点对预测结果的影响程度, 即引入应变先验对神经网络注意力权重的影响。本文对网络的最后一层进行可视化, 通过各通道间的加权融合获取类激活热力图(图 6), 观测引入应变先验对网络注意力的影响。基础的 U-Net 网络关注的是一些材料本身的内部组织结构或者裂纹的一小部分, 引入应变先验后, 可以较准确地关注到裂纹所在区域。引入应变先验可以引导网络关注裂纹区域, 减少对其他区域的关注, 进而提高后续损伤识别效果。通过对神经网络推理过程可视化, 证明了应变先验的有效性。

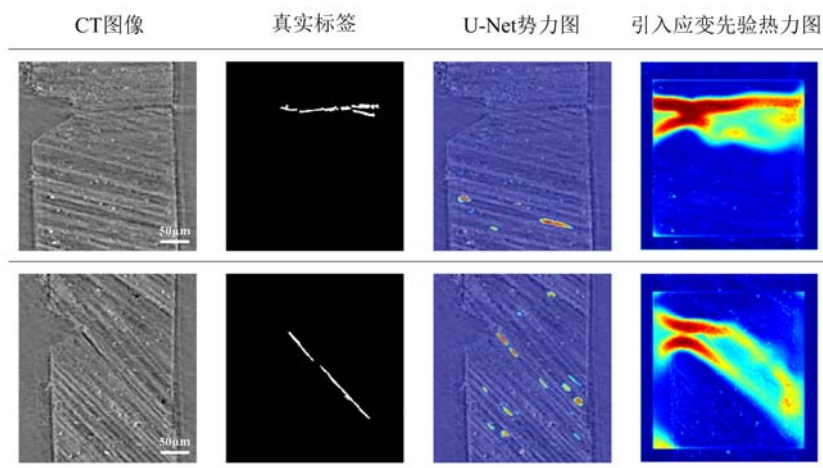


图 6 类激活热力图对比

Fig. 6 Comparison of class activation map

2 原位力学 CT 实验验证

2.1 数据集及实验设置

本文采用一种螺旋叠层复合材料(仿螳螂虾结构)的原位拉伸实验 CT 图像作为数据集。实验从初始无加载状态(0 状态)到最后完全断裂状态(8 状态)共拍摄 9 个状态的图像。该数据集包含 534 张切片图,图像为 tif 格式单通道灰度图,图像大小均为 $941 \text{ pixel} \times 1000 \text{ pixel}$ 。对每张图像的裂纹区域进行像素级标注,得到每张图像的真实标签图。对数据集应用水平翻转、垂直翻转、旋转($45^\circ, 60^\circ$)、对比度增强、平移进行数据集增强。其中,随机选取 30 张作为测试集,剩余图像按照 9 : 1 的比例分为训练集和验证集。

基于 DVC 应变先验引导的裂纹分割方法在进行学习训练时需要应变图谱。这里选取大小为 $61 \text{ voxel} \times 61 \text{ voxel} \times 61 \text{ voxel}$ 的子区进行匹配计算,以材料的 3 状态和 4 状态为例提取三维应变场,结果如图 7 所示,并切割出与 CT 图像对应的二维应变图谱。




图 7 三维应变场计算结果

Fig. 7 Calculation of three-dimensional strain field

软件环境及硬件配置: Python3.10 运行环境, Pytorch3.9 深度学习框架, CUDA11.7 加速框架; Windows10 操作系统, NVIDIA GeForce GTX 3090 GPU 显卡, Intel(R) Core(TM) i7-8700 CPU 处理器。

参数设置: 将输入的图片进行缩放, 缩放因子为 0.5。训练批量大小(batch_size)设置为 8, 应用 RMSprop 优化器, 初始学习率(learning rate)设置为 0.0001, 学习率在训练过程中不断降低(当对应指标停止优化 2 个 epoch 后, 降低学习率, 每次降低比例为 0.1), 权重衰减因子(weight decay)设置为 10^{-8} 。进行 50 次迭代(epoch)训练后, 达到收敛, 保存最后一次迭代的模型用于测试。其中损失函数的

权重系数 $a=b=1$ 。

2.2 基于图像分割的损伤识别质量评价

图 8 展示了 U-Net 和基于应变先验引导的 U-Net 方法的二维分割结果,实线椭圆框所选区域突出显示出基于应变先验引导的 U-Net 方法在识别微小裂纹上的优越性,虚线椭圆框所选区域突出显示出基于应变先验引导的 U-Net 方法在减少错误识别上的优越性。将二维分割结果堆叠成三维体,实现裂纹的三维可视化,如图 9 所示。由于该材料是螺旋结构,所以其三维裂纹也呈现螺旋状分布,图 9 分别展示了基础 U-Net 方法和引入应变先验约束的 U-Net 方法的裂纹识别结果。从三维效果可见,加入应变先验约束后可以更好地分割出裂纹区域,能够完整地展现裂纹的形状和方向。由各个螺旋层的 CT 断层图可知,图 9 中的黑色虚线框中未包括裂纹损伤的区域被 U-Net 方法错误分割,而应变先验引导方法则避免了这一错误,突出显示出该方法减少错误识别的优势。

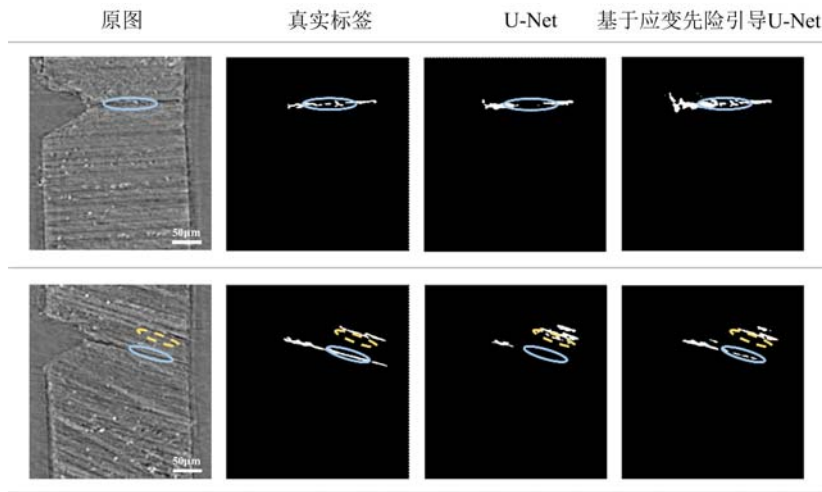


图 8 分割效果对比

Fig. 8 Comparison of segmentation effect




图 9 内部裂纹的三维可视化

Fig. 9 Three-dimensional visualization of internal cracks

本文对 6 组测试集进行实验,并以精确率(Precision)、召回率(Recall)、交并比(IoU)以及 F1-score 作为分割性能评价指标,以此验证本文提出方法的有效性,相关公式如下:

$$\text{Precision} = \text{TP}/(\text{TP} + \text{FP}) \quad (5)$$

$$\text{Recall} = \text{TP}/(\text{TP} + \text{FN}) \quad (6)$$

$$\text{IoU} = \text{TP}/(\text{TP} + \text{FP} + \text{FN}) \quad (7)$$

$$\text{F1-score} = (2 \times \text{Precision} \times \text{Recall})/(\text{Precision} + \text{Recall}) \quad (8)$$

式中: TP(True Positive)代表真阳性,即预测为正例,实际上也是正例的像素点个数;FP(False Positive)代表假阳性,即预测为正例,实际上是反例的像素点个数;FN(False Negative)代表假阴性,即预测为反例,实际上是正例的像素点个数;TN(True Negative)代表真阴性,即预测为反例,实际上也是反例的像素点个数。精确率(Precision)表示在预测为正例的样本中预测正确的概率;召回率(Recall)表示实际为正例的样本中预测正确的概率;交并比(IoU)表示预测标签与真实标签之间的交并比,用来衡量预测标签和真实标签之间的相似性;F1-score是 Precision 和 Recall 的加权调和平均,用来综合考虑这一对矛盾的评价指标。

本实验共6个测试组,从图10的图像分割评价指标上来看,2个方法除了召回率在不同的测试组上各有优势外,其余3个评价指标采用本文提出的方法均优于基础的U-Net方法,也就是说本文提出的方法分割性能有所优化。综合所有测试数据,得到分割效果评价指标见表1。由表可见,基于应变先验引导的U-Net方法的 Precision、Recall、IoU 和 F1-score 指标分别为 82.74%、75.16%、69.66%、78.44%,比基础的U-Net方法分别提高了大约26%、3%、15%、15%,说明引入应变引导约束后,识别的精确率大幅提升,也减少了错误识别的概率,使得预测结果与真实标签更加相似。

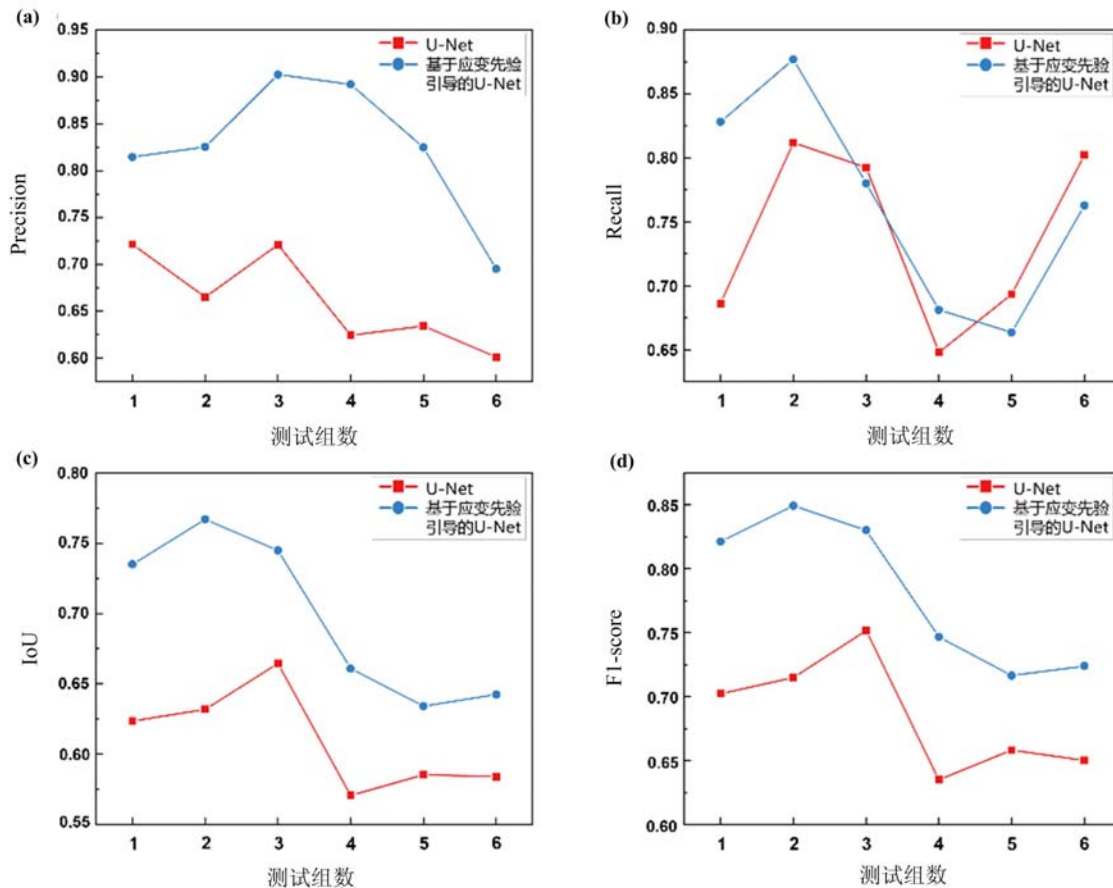


图10 不同测试组的评价指标对比

Fig. 10 Comparison of evaluation indexes of different test groups

表 1 图像分割评价指标
Tab. 1 Image segmentation evaluation index table

	Precision	Recall	IoU	F1-score
U-Net	65.55%	72.65%	60.74%	68.40%
基于应变先验引导的 U-Net	82.74%	75.16%	69.66%	78.44%

2.3 基于力学参量的损伤识别质量评价

考虑到力学分析中对裂纹萌生位置、裂尖扩展方向等力学参量的关注,本文基于裂尖坐标提出了一个力学参量评价指标——尖端坐标偏差(Dev),即预测裂纹尖端坐标与真实标签中裂纹尖端坐标的偏差与真实裂纹长度的比值,以此来衡量裂纹分割方法对裂纹萌生位置的判断是否准确,相关公式为

$$\text{Dev} = \sqrt{(x - x_0)^2 + (y - y_0)^2} / L_0 \quad (9)$$

式中: x 、 y 为预测裂纹尖端坐标; x_0 、 y_0 为真实标签中裂纹尖端坐标。

提取裂纹尖端坐标方法如下:(1)对网络得到的分割二值图进行连通域标记,对单张图像中的裂纹分别编号,以便后续匹配。(2)提取每个裂纹的两侧端点坐标。(3)根据相邻状态判断裂纹扩展方向,靠近扩展方向那一侧的端点即为裂尖坐标。

从图 11 可见,基于应变先验引导的 U-Net 方法分割得到的裂尖处坐标偏差明显小于 U-Net。综合 6 组测试数据,引入应变先验引导的方法坐标偏差平均值为 35.92%,而 U-Net 方法的坐标偏差平均值为 14.31%,坐标偏差降低了约 60%,可见引入应变先验可以更加精准地确定裂纹萌生阶段裂尖的位置。

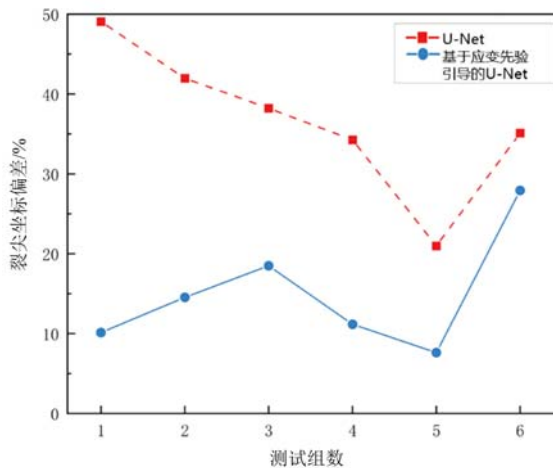


图 11 裂纹尖端坐标偏差

Fig. 11 The coordinate deviation of the crack tip

3 结论

本文针对原位力学 CT 数据损伤演化特征识别提取的难题,采用引入力学参量约束神经网络思路,提出了一种基于 DVC 应变先验的损伤识别方法。将应变图谱与 CT 图像融合,考虑损伤的力学特征,引导网络关注应变集中区域,即裂纹可能出现的区域。为了验证该方法的有效性,将其应用于复合材料原位拉伸实验 CT 图像的损伤识别,损伤识别的提取效果得到改善,相关的评价指标明显提升。结果表明该方法不仅可以有效识别微小裂纹,还能够减少材料本身结构特征干扰损伤特征所导致的错误识别。同时,该方法识别结果的裂尖坐标偏差值也显著降低,提高了对裂尖定位的准确性。本文所发展方法可以为损伤演化机理的研究提供实验数据支撑。

参考文献:

- [1] 钟群鹏, 周煜, 张峥. 裂纹学[J]. 中国工程科学, 2015, 17(3):113 (ZHONG Qunpeng, ZHOU Yu, ZHANG Zheng. Crackology[J]. Chinese Engineering Science, 2015, 17(3):113 (in Chinese))
- [2] 陈帅, 黄念, 李建乐, 等. 基于分布式光纤传感信号的结构损伤识别主成分分析方法[J]. 实验力学, 2022, 37(6):838—846 (CHEN Shuai, HUANG Nian, LI Jianle, et al. Principal component analysis for structural damage identification based on distributed optical fiber sensing signals [J]. Journal of Experimental Mechanics, 2022, 37(6):838—846 (in Chinese))
- [3] HU X, FANG J, XU F, et al. Real internal microstructure based key mechanism analysis on the micro-damage process of short fibre-reinforced composites[J]. Scientific Reports, 2016, 6(1):34761.
- [4] JI X L, ZHOU W, SUN H, et al. Damage evolution behavior of bi-adhesive repaired composites under bending load by acoustic emission and micro-CT[J]. Composite Structures, 2022, 279:114742.
- [5] WU S, XIAO T, WITHERS P. The imaging of failure in structural materials by synchrotron radiation X-ray microtomography[J]. Engineering Fracture Mechanics, 2017, 182:127—156.
- [6] DU F, WANG K, ZHANG G, et al. Damage characteristics of coal under different loading modes based on CT three-dimensional reconstruction[J]. Fuel, 2022, 310:122304.
- [7] 唐昫超, 陈正, 黄钊丰, 等. 基于 U-net 神经网络算法和改进的细化算法的水坝混凝土裂缝测量[J]. 实验力学, 2022, 37(2):209—220 (TANG Yunchao, CHEN Zheng, HUANG Zhaofeng, et al. Visual measurement of dam concrete cracks based on U-net and improved thinning algorithm[J]. Journal of Experimental Mechanics, 2022, 37(2):209—220 (in Chinese))
- [8] XIAO C, BUFFIERE J Y. Neural network segmentation methods for fatigue crack images obtained with X-ray tomography[J]. Engineering Fracture Mechanics, 2021, 252:107823.
- [9] COMMANDEUR F, GOELLER M, BETANCUR J, et al. Deep learning for quantification of epicardial and thoracic adipose tissue from non-contrast CT[J]. IEEE Transactions on Medical Imaging, 2018, 37(8):1835—1846.
- [10] CHEN J, LIU Y. Fatigue modeling using neural networks: a comprehensive review[J]. Fatigue & Fracture of Engineering Materials & Structures, 2022, 45(4):945—979.
- [11] MENASCHE D B, SHADE P A, SAFRIET S, et al. Deep learning approaches to semantic segmentation of fatigue cracking within cyclically loaded nickel superalloy [J]. Computational Materials Science, 2021, 198:110683.
- [12] QIU J, LI Y, XU F, et al. Strain induced crack initiation and the subsequent crack propagation of fiber-reinforced resin composites[J]. Composites Part A: Applied Science and Manufacturing, 2022, 155:106836.
- [13] 杨鹏, 万克树, 秦天旸. X-CT 噪音条件下数字体积相关算法评测[J]. 实验力学, 2014, 29(5):589—600 (YANG Peng, WAN Keshu, QIN Tianyang. Digital volume correlation algorithm evaluation under X-CT noise condition[J]. Journal of Experimental Mechanics, 2014, 29(5):589—600 (in Chinese))
- [14] 袁山明, 苏勇, 肖宇, 等. 基于体素选择的自适应数字体积相关方法[J]. 实验力学, 2023, 38(2):165—175 (YUAN Shanming, SU Yong, XIAO Yu, et al. Self-adaptive digital volume correlation based on voxel selection [J]. Journal of Experimental Mechanics, 2023, 38(2):165—175 (in Chinese))
- [15] 潘兵, 王博. 数字体图像相关方法研究进展[J]. 科学通报, 2017, 62(16):1671—1681 (PAN Bing, WANG Bo. Research progress in digital volume correlation method[J]. Chinese Science Bulletin, 2017, 62(16):1671—1681 (in Chinese))
- [16] RREEJA P, HARIHARAN S. Three-dimensional fusion of clustered and classified features for enhancement of liver and lesions from abdominal radiology images[J]. IET Image Processing, 2019, 13(10):1680—1685.
- [17] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation [C]//Medical Image Computing and Computer-Assisted Intervention-MICCAI, 2015:234—241.
- [18] ZHOU B, KHOSLA A, LAPEDRIZA A, et al. Learning deep features for discriminative localization [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016:2921—2929.

A prior-based strain identification method based on digital volume correlation

CANG Jiaoqing¹, XIAO Yu¹, SU Yong², WANG Honghan¹, HU Xiaofang¹, XU Feng¹

(1. Department of Modern Mechanics, CAS Key Laboratory of Mechanical Behavior and Design of Materials, University of Science and Technology of China, Hefei 230026, Anhui, China; 2. School of Biomedical Engineering, Anhui Medical University, Hefei 230032, Anhui, China)

Abstract: It is key to prevent fracture failure by investigating the failure process and revealing the evolution mechanism of internal damage. Computed tomography (CT) can provide three-dimensional characterization of the internal damage evolution process, which supports the research of the internal damage evolution mechanism of materials. However, the quantitative recognition and extraction of damage evolution faces the challenge of weak damage feature signals being overshadowed by the complex structural signals of CT images. The idea of introducing mechanical parameters to guide neural networks was proposed. Three-dimensional strain fields obtained based on Digital Volume Correlation (DVC) were used as priori information of mechanical parameters to guide and constrain network training, enabling crack identification and extraction. Through quantitative evaluation and verification of actual CT experimental data, the method can improve micro crack identification precision and reduce the identification error rate.

Keywords: CT image; digital volume correlation; strain; internal damage identification; neural network