

DOI:10.16356/j.2097-6771.2026.01.012

## 基于生成对抗网络的纤维增强复合材料横向性能预测

吴嘉炜<sup>1</sup>, 王新峰<sup>1</sup>, 于健<sup>2</sup>, 黄再兴<sup>1</sup>

(1. 南京航空航天大学航空学院, 南京 210016; 2. 南京航空航天大学通用航空与飞行学院, 南京 211106)

**摘要:** 本文针对纤维增强复合材料微观应力/应变/损伤场预测问题, 提出了一种融合残差连接与 PixelShuffle 上采样的条件生成对抗网络(Conditional generative adversarial network, cGAN), 记作 RP-cGAN, 以解决有限元方法建模复杂、计算效率低及现有机器学习模型对界面过渡区预测精度不足的问题。基于真实材料分布特征和参数, 建立代表性体积单元模型, 生成 T300 材料在拉伸/剪切载荷下的多场数据集。RP-cGAN 通过残差连接增强界面特征提取能力, 使过渡区预测误差降低 30%。并结合 PixelShuffle 上采样将峰值信噪比提升 7%, 有效抑制了传统转置卷积的棋盘效应。实验表明, 该模型在 26 ms 内可完成单幅云图预测, 且在多载荷工况下保持稳定性能(SSIM>0.983 9)。RP-cGAN 在损伤云图预测时, 基于 Mises 应力准则和刚度退化下的预测结果与有限元计算高度一致, 为复合材料多尺度失效分析提供了高效精准的计算工具。

**关键词:** 纤维增强复合材料; 界面过渡区; 条件生成对抗; 代表性体积单元; 云图预测

中图分类号: TB332

文献标志码: A

文章编号: 1005-2615(2026)01-0134-09

## Prediction of Transverse Properties of Fiber-Reinforced Composites Based on Generative Adversarial Networks

WU Jiawei<sup>1</sup>, WANG Xinfeng<sup>1</sup>, YU Jian<sup>2</sup>, HUANG Zaixing<sup>1</sup>

(1. College of Aerospace Engineering, Nanjing University of Aeronautics & Astronautics, Nanjing 210016, China;

2. College of General Aviation and Flight, Nanjing University of Aeronautics & Astronautics, Nanjing 211106, China)

**Abstract:** This paper addresses the problem of predicting stress/strain/damage fields at the microscale in fiber-reinforced composite materials. It proposes a conditional generative adversarial network (RP-cGAN) that integrates residual connections and PixelShuffle up-sampling to solve issues with complex finite element method modeling, low computational efficiency, and insufficient accuracy of existing machine learning models in predicting interface transition zones. Based on the real material distribution characteristics and parameters, a representative volume element model is established to generate multi-field datasets for T300 materials under tensile/shear loads. The RP-cGAN enhances the extraction of interface features through residual connections, reducing the prediction error of the transition zone by 30%. Additionally, it combines PixelShuffle up-sampling to increase the peak signal-to-noise ratio by 7%, effectively suppressing the checkerboard effect of traditional transposed convolutions. Experiment results show that the model can complete a single cloud map prediction in 26 ms and maintain stable performance under multiple load conditions (SSIM > 0.983 9). When predicting damage clouds, the RP-cGAN results based on the Mises stress criterion and predictions under stiffness degradation are highly consistent with finite element calculations, providing an efficient and precise computational tool for multiscale failure analysis of composite

**基金项目:** 江苏省自然科学基金青年基金(BK20220871); 中国博士后科学基金(2023M741691)。

**收稿日期:** 2025-06-29; **修订日期:** 2025-09-01

**通信作者:** 黄再兴, 男, 教授, 博士生导师, E-mail: huangzx@nuaa.edu.cn。

**引用格式:** 吴嘉炜, 王新峰, 于健, 等. 基于生成对抗网络的纤维增强复合材料横向性能预测[J]. 南京航空航天大学学报(自然科学版), 2026, 58(1): 134-142. WU Jiawei, WANG Xinfeng, YU Jian, et al. Prediction of transverse properties of fiber-reinforced composites based on generative adversarial networks[J]. Journal of Nanjing University of Aeronautics & Astronautics(Natural Science Edition), 2026, 58(1): 134-142.

materials.

**Key words:** fiber-reinforced composite materials; interphase transition zones; conditional generative adversarial network(cGAN); representative volume element; cloud map prediction

碳纤维增强复合材料因其优异的比强度、刚度和设计能力,在航空航天、武器等领域获得广泛应用。然而,其复杂的多相异质结构导致力学响应具有显著的多尺度特征,特别是在横向载荷作用下,纤维-基体界面效应会引发局部应变集中,最终影响宏观性能<sup>[1]</sup>。为了预测复合材料的弹性性能,已经发展出了多种等效理论模型。包括基于Eshelby夹杂理论,计算纤维体积分数和形状对有效模量的影响,结合局部应力场预测基体或界面失效的Mori-Tanaka方法;可通过修正公式关联体积分数和纤维形状对横向强度影响的Halpin-Tsai半经验模型等。而对于微观建模,需要得到纤维材料的横向材料参数并不是十分容易。Miyagawa等<sup>[2-3]</sup>通过多种方法评估了碳纤维的横向弹性模量,如拉曼光谱测量、纳米压痕法以及二维和三维有限元法等,结合试验结果确定了Halpin-Tsai方程提供的值更接近实验结果。

随着计算机的发展,由本构模型和损伤模型建立的有限元方法逐渐成为分析复合材料性能的主流<sup>[4-5]</sup>,包括通过界面断裂能和强度参数预测脱粘起始与扩展的内聚力模型;建立包含纤维分布、形状及界面的代表性体积单元(Representative volume element, RVE)模型等。基于有限元方法的多尺度模拟虽然精度可靠,但计算成本依旧高昂,尤其在参数优化和不确定性分析时效率低下<sup>[6]</sup>,微观尺度RVE的精细化建模需消耗大量计算资源,而宏观尺度性能预测的迭代优化过程进一步加剧了计算负担。为突破这一限制,研究者提出以机器学习驱动的替代模型替代传统数值方法,通过数据驱动方式直接建立输入参数与输出场量的映射关系,显著缩短了计算周期<sup>[7-9]</sup>。Pathan等<sup>[10]</sup>采用梯度提升树回归模型预测单向复合材料的宏观刚度与屈服强度;Rao等<sup>[11]</sup>则利用相似架构预测颗粒增强复合材料的各向异性有效性能。这些工作标志着机器学习在复合材料性能预测领域的初步渗透,但主要集中于均质化性能(如等效刚度、强度)的宏观预测,对局部应力/应变场的精细化表征能力仍显不足。局部应力场的高精度预测对复合材料失效分析至关重要,但均质化方法难以捕捉微结构异质性引发的应力集中效应。近年来,深度学习技术凭借其强大的非线性映射与特征提取能力,在应力场预测领域取得显著突破。

Nie等<sup>[12]</sup>提出两种卷积神经网络(Convolutional neural network, CNN)架构:单通道应力网络(Single-channel stress network, SCSNet)与融合压缩激

励-残差-全卷积网络(Squeeze-and-excitation residual fully convolutional network, SE-Res-FCN),成功预测二维悬臂梁结构的 von Mises 场,验证了CNN在应力场重建中的潜力。然而,传统CNN模型在应对复杂边界条件与多物理场耦合时,易受感受野限制,难以有效建模长程空间相关性。为克服CNN的局限性,研究者转向具有更强生成能力的GAN架构<sup>[13-15]</sup>。Jiang等<sup>[16]</sup>提出StressGAN,首次将条件生成对抗网络(Conditional generative adversarial network, cGAN)应用于固体结构二维 von Mises 分布预测,通过对抗训练机制提升应力场细节重构能力。Yang等<sup>[17]</sup>进一步扩展cGAN框架,实现从材料微结构到全场应力/应变的直接映射。原始cGAN模型在训练稳定性与高频细节保留方面仍存在短板,亟待通过结构改进提升其预测精度与鲁棒性。现有研究表明,纤维增强复合材料的损伤萌生机制具有显著取向依赖性。Sepasdar等<sup>[18]</sup>通过精细化建模揭示了此类材料损伤主要萌生于横向载荷作用下的纤维-基体界面过渡区域,而非纤维本体方向。当前基于cGAN的预测模型<sup>[17]</sup>在构建含界面过渡区的多场云图时仍存在显著精度偏差,且现有研究多局限于单一拉伸载荷工况,而对剪切载荷下的应变场和损伤场预测缺乏详细探讨。

本文提出Residual Pixelshuffle-cGAN(RP-cGAN)模型以解决上述挑战,首要目标是解决cGAN模型对引入过渡区后的多场预测精度下降的问题,主要包括引入残差链接模块增强梯度反向传播能力,缓解梯度消失并增强界面局部特征提取能力,从而减少集中区域均方误差(Concentrated region mean squared error, C-MSE);为了提升场变量空间连续性指标(如Frechet inception距离(Frechet inception distance, FID)和峰值信噪比(Peak signal-to-noise ratio, PSNR)),通过将PixelShuffle上采样与传统的转置卷积相结合来抑制棋盘状伪影。再通过对训练数据的特征处理,最终使得RP-cGAN模型对含过渡区的纤维增强复合材料在单向拉伸和面内剪切载荷下的多场云图预测上,均表现出了良好的准确性,尤其是界面区域的预测误差的降低,并对不同载荷工况的模型均保持了良好的鲁棒性。

## 1 实验设计

### 1.1 数据集构建

采用二维平面应力RVE模型,对T300纤维增

强复合材料垂直于纤维方向的横截面进行建模,包含基于线弹性假设的纤维材料和基体材料,并加入了纤维和基体之间过渡区的建模。Gu 和 Niu 等<sup>[19-20]</sup>使用纳米 DMA 技术对 Toray Inc. 生产的直径约为  $7\ \mu\text{m}$  的 T300 碳纤维嵌入环氧基体进行了扫描成像,得到了 T300 碳纤维增强环氧树脂复合材料样品的原位地形图像及其对应的储存模量,并提取出过渡区的宽度为  $(118 \pm 3)\ \text{nm}$ ,储存模量在  $5\sim 20\ \text{GPa}$ 。Bu 等<sup>[21]</sup>的研究结果表明,当过渡层厚度与纤维半径之比小于 0.04 时,过渡层对 CFRP 复合材料弹性性能的影响较小。依据上述研究,本文在构建有限元数据集时,采用的材料参数如表 1 所示。

表 1 有限元材料参数

Table 1 Finite element material parameters

参数	纤维	过渡区	基体
横向弹性模量/GPa	17.4	10.0	3.0
横向泊松比	0.3	0.3	0.3

RVE 模型由 Hill<sup>[22]</sup>提出,定义为最小的材料体积元素。对于宏观本构,最小体积元足以准确代表材料的平均本构特征<sup>[23]</sup>。对于纤维增强复合材料在拉伸和剪切载荷作用下,采用周期性分布的 RVE 模型足以有效表征材料的宏观等效性能,误差小于 5%<sup>[24]</sup>。但是,若要从微观结构角度分析材料的应力和应变场时,周期性材料无法准确反映材料内部可能会出现的情况,如应力集中和损伤起始。

当采用非周期性建模时,会出现由 RVE 边界的存在,导致局部材料微观结构、纤维排布或力学行为与材料内部自由区域出现显著差异的现象,例如边界可能阻碍纤维均匀分布,形成树脂含量较高的边界层,这样的壁面会改变局部应力场,影响界面应力传递效率(如纤维-基体脱粘易从边界起始)。根据 Gitman 的研究<sup>[24]</sup>,拉伸工况下即使存在边界效应,RVE 尺寸对应力预测的影响依旧较小。而剪切工况下,测试表现出显著的 RVE 尺寸敏感性,需要极大的 RVE 尺寸才能达到小于 5% 的误差,在 20%~60% 体积分数范围内,RVE 边长至少为纤维直径的 6 倍才能达到 95% 以上的准确率。这来源于剪切载荷下的刚度匹配需求,周期性材料保证了试样对边刚度对称,而非周期性材料因壁面效应导致局部刚度突变(如一侧纤维富集、另一侧树脂富集),引发应力集中和响应离散,剪切变形依赖界面传递效率,边界效应直接破坏剪切应力的周期性传递路径。

综合考虑计算效率和非周期性建模所引起的剪切工况下的误差,如图 1 所示,本研究采用的是

$7\ \mu\text{m}$  纤维直径和  $120\ \mu\text{m} \times 120\ \mu\text{m}$  的平面应力 RVE 模型。使用 ABAQUS 有限元分析软件及 RVE 插件<sup>[25]</sup>,对模型边界施加周期边界条件。并通过 Python 程序实现纤维的随机插入与批量化建模。载荷施加方式如图 2 所示,对于拉伸载荷和剪切载荷在同一数据集中时,通过增加载荷标签的形式做区分。通过在原始图像和云图上叠加一条单像素宽度的线作为不同载荷的标签。

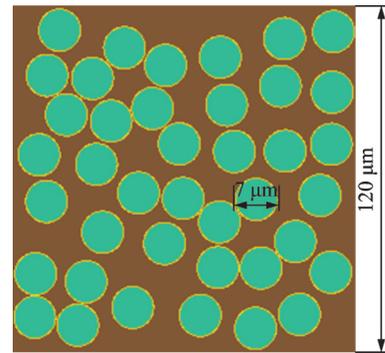


图 1 纤维直径及 RVE 尺寸示意图

Fig.1 Illustration of fiber diameter and RVE dimensions

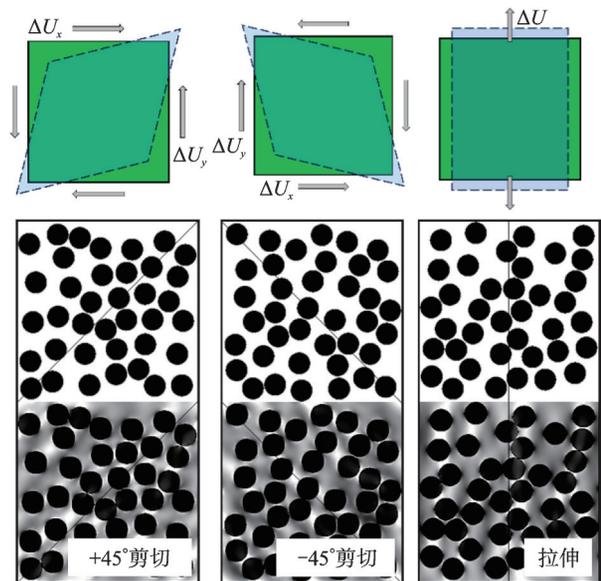


图 2 载荷施加方式及方向标签

Fig.2 Load method and direction label

图 3 为 González 等<sup>[26]</sup>通过电子显微镜拍摄的碳纤维复合材料横截面的真实图像,可以注意到材料内部的纤维分布存在明显的纤维稀疏区和纤维密集区。在构建数据集时,以 60% 纤维体积分数为上限,20% 纤维体积分数为下限,充分考虑了纤维体积分对云图结果的影响,创建了拉伸和剪切下载荷下的应力云图和应变云图。基于上述建模方法,本研究严格遵循实际材料分布特征及材料参数,确保了单个 RVE 样本能够充分表征材料在微观尺度下的力学特征。相较于需要学习复杂通用模式的图像任务模型,GAN 网络能够在小样本条件下,充分且高效地学习明确物理规律主导的、具

有强代表性的数据集<sup>[27]</sup>。数据集的具体类型和数量分配如表 2 所示。

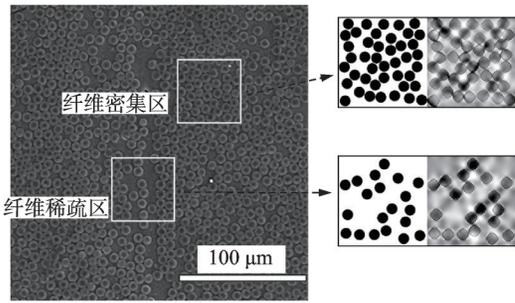


图 3 横向压缩下加载的试样横截面的扫描电子显微镜图及有限元模型<sup>[26]</sup>

Fig.3 Scanning electron microscope images and finite element models of the cross-sections of specimens loaded in compression<sup>[26]</sup>

表 2 数据集类型和数量

Table 2 Type and quantity of datasets

载荷形式	20%~40% 纤维体积分数			40%~60% 纤维体积分数		
	训练集	验证集	测试集	训练集	验证集	测试集
+45°剪切	84	18	18	336	72	72
-45°剪切	84	18	18	336	72	72
90°拉伸	84	18	18	336	72	72

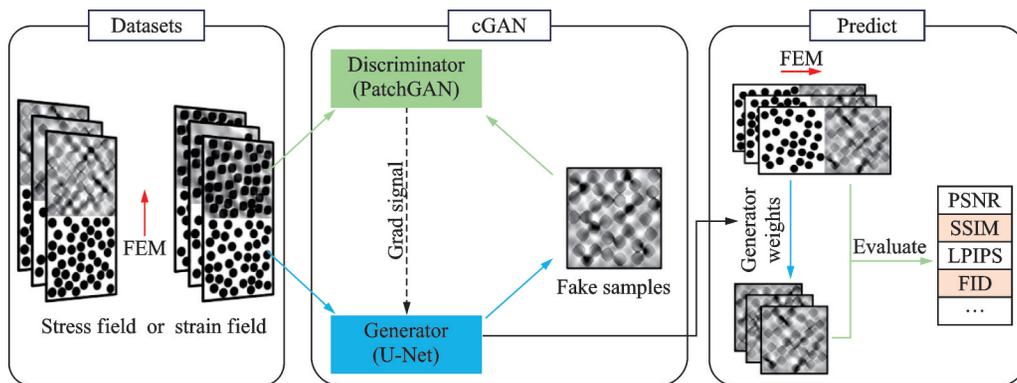


图 4 用于云图预测的生成对抗网络构建

Fig.4 A generative adversarial network for cloud map prediction

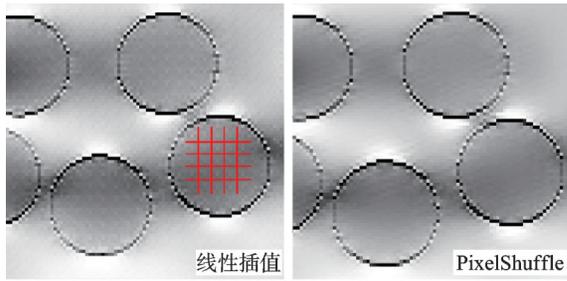
基础的 cGAN 生成器采用编码器-解码器结构,通过连续的转置卷积进行上采样。这种结构的潜在问题如:深层网络梯度逐层传递时易发生衰减;深层特征表达能力受限,导致生成质量下降;高频细节信息在多层非线性变换中逐步丢失。体现在纤维增强材料的云图的预测上就是过渡区以及纤维密集区的应力或者应变集中区的预测准确度可能会下降。改进的 cGAN 架构在上采样路径引入残差连接,通过引入一种“跳跃”机制来解决这个问题。残差连接通过允许梯度沿多条路径传播,直接将输入传递给下一层,或者将当前层的输出与输入相加后传递给下一层,有效缓解了深层网络中的梯度消失问题,这种设计在理论上等效于构建多个

## 1.2 网络配置

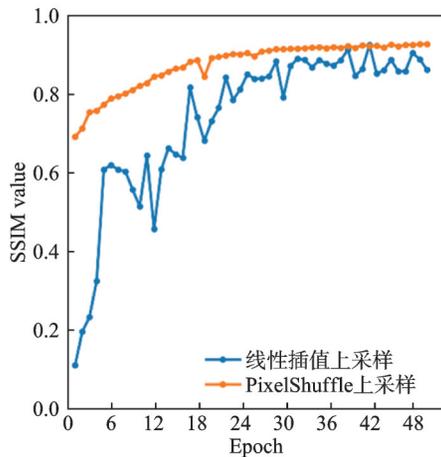
使用 ABAQUS 软件对 RVE 模型进行有限元仿真分析,可以得到应力场和应变场云图。如图 4 左侧数据集部分,一张 RVE 模型材料分布图和一张云图可以作为一组输入输出图像数据,用于训练深度学习模型。如图 4 中间部分所示,cGAN 网络由生成器和判别器组成。生成器采用广泛应用于图像处理和图像特征捕捉的 U-Net 结构<sup>[28]</sup>。判别器采用 PatchGAN 架构设计<sup>[29]</sup>,其核心思想是通过局部感受野对图像进行分块判别。RVE 模型的有限元建模图作为输入条件,生成器输出预测图,判别器通过鉴别预测图和有限元仿真得到的图像,输出一个 30×30 的矩阵,矩阵的每个元素对应输入图像中一个局部区域的“真实性”概率,用来指导生成器调整对应区域的像素值。经过多轮循环训练后,可以得到生成器的权重结果,将测试用的数据集输入给包含权重结果的生成器可以得到最终的预测图像。可以通过多个指标如:PSNR、结构相似性指数 (Structural similarity index measure, SSIM)、学习感知图像块相似度 (Learned perceptual image patch similarity, LPIPS)···对模型的准确性进行评价。

浅层网络的集成,提升了模型的整体表达能力和泛化能力。而且由于梯度传播得更加稳定,有助于加速模型的收敛过程。这使得训练时间缩短,同时保持或提升生成图像的质量。

对于本研究这种重点关注图像细节质量的网络,传统的上采样方法(如双线性插值或最近邻插值)可能会产生明显的锯齿边缘,或者出现如图 5(a)所示的棋盘格效应,尤其是当图像分辨率较高时,这种情况会更加明显。PixelShuffle<sup>[30]</sup>将通道维度的像素信息重新排列到空间维度,避免了传统转置卷积的重叠填充操作,规避了棋盘格效应的产生条件。同时,棋盘格这种人为引入的误差,会影响模型训练前期的效率。图 5(b)是剪切载荷下应力云



(a) Comparison of cloud maps from linear interpolation up-sampling and PixelShuffle up-sampling



(b) Epoch-SSIM curves of stress cloud map under shear load

图 5 棋盘格效应及 PixelShuffle 技术对模型的影响

Fig.5 Checkerboard effect and the impact of PixelShuffle on the model

图的 Epoch-SSIM 曲线, PixelShuffle 对模型早期的学习效率有显著的提高。

对于本研究的 RP-cGAN 网络,网络超参数包括模型架构超参数和训练配置超参数。具体超参数设置如表 3 所示。训练轮数(Epochs)作为主要影响训练总时长的参数,会显著影响模型最终的预测精度。本研究综合考虑训练效率和预测精度,引入早停参数,SSIM 在 50 个 Epochs 内没有提升则终止训练,并设置训练轮数上限。

表 3 RP-cGAN 超参数

Table 3 Hyperparameters of the RP-cGAN

模型超参数	值	训练超参数	值
下采样层数	8 layers	学习率	$1e-4$
上采样层数	7 layers + PixelShuffle layer	Adam 优化器	$\beta_1=0.5,$ $\beta_2=0.999$
下采样卷积核	$4*4$	Batch_size	4
上采样卷积核	$3*3$	Epochs	1 000
Dropout ratio	0.5	Early_stop	50

表 4 拉伸载荷下的应力云图预测结果评价

Table 4 Evaluation of stress cloud map prediction results under tensile load

模型	MAE	MSE	LPIPS	FID	PSNR	SSIM	C-MSE	GMS
cGAN	0.018 5	0.000 7	0.009 9	8.968 9	31.306 9	0.978 8	0.001 8	0.996 6
R-cGAN	0.015 7	0.000 5	0.005 6	<b>2.244 0</b>	32.986 2	0.990 7	0.001 2	0.998 0
P-cGAN	0.015 7	0.000 5	0.007 0	4.355 8	32.776 8	0.987 6	0.001 5	0.997 8
RP-cGAN	<b>0.014 9</b>	<b>0.000 4</b>	<b>0.004 9</b>	2.253 7	<b>33.500 6</b>	<b>0.990 8</b>	<b>0.001 2</b>	<b>0.998 2</b>

## 2 结果与分析

### 2.1 定量分析指标

为了评估网络的有效性,需要从多个角度来衡量其性能。首先,对于预测结果与有限元结果的应力/应变数值的误差,可以通过平均绝对误差(Mean absolute error, MAE)和均方误差(Mean squared error, MSE)两个指标评价。1.2 节中提到的棋盘格效应是一种高度规则、周期性、高频的人工伪影,可通过 FID 和 LPIPS 两个指标对图像的结构失真(如模糊、扭曲、不自然的图案)进行检验。对于预测云图和有限元云图之间的相似程度,采用 PSNR 和 SSIM 两个指标评价。PSNR 是基于 MSE 的全局度量,适合评价应力/应变幅值的整体准确性,若应力/应变集中区域出现较大偏差,PSNR 会显著下降。SSIM 通过计算局部窗口的亮度、对比度和结构的相似度,再对所有窗口求均值得到最终的结构相似性评价,更适合评价应力云图的形态学特征。由于纤维增强复合材料的损伤起始普遍在纤维基体界面或者高应力应变区,所以使用 C-MSE 和梯度幅值相似性(Gradient magnitude similarity, GMS)两个指标评价。C-MSE 是在 MSE 的基础上增加标注掩膜 M,只计算数值超过或者小于规定范围内的区域的均方误差。GMS 则基于人眼视觉系统(HVS)对图像边缘和纹理(即梯度信息)的变化敏感和图像的局部区域内梯度幅值分布的稳定性来量化相似性。

### 2.2 实验结果

消融实验是机器学习和深度学习研究中验证模型组件有效性的核心方法。通过消融实验分析残差连接和 PixelShuffle 对模型的贡献度。固定实验超参数(表 3)和硬件环境(i5-12600kf+RTX4080),实验一共包含 4 种模型,分别为:原始 cGAN 模型、仅引入残差连接的 R-cGAN 模型、仅引入 PixelShuffle 的 P-cGAN 模型和残差连接与 PixelShuffle 耦合的 RP-cGAN 模型。应用上一节提到的 8 个指标来评估不同模型在拉伸应力云图数据集上的准确度。表 4 为 4 个模型分别对拉伸载荷下对应力云图的预测结果评价。通过具体数值可以看到,残差连接和 PixelShuffle 对预测的准确度均有一定的贡

献,其中FID和PSNR两个评价指标的提升较为显著。图6为cGAN模型和RP-cGAN模型在不同工况下的典型预测结果的误差云图。可以看到,

RP-cGAN模型显著降低了树脂区和过渡区的预测误差。同时引入残差链接和PixelShuffle的RP-cGAN模型表现出了最好的预测准确度。

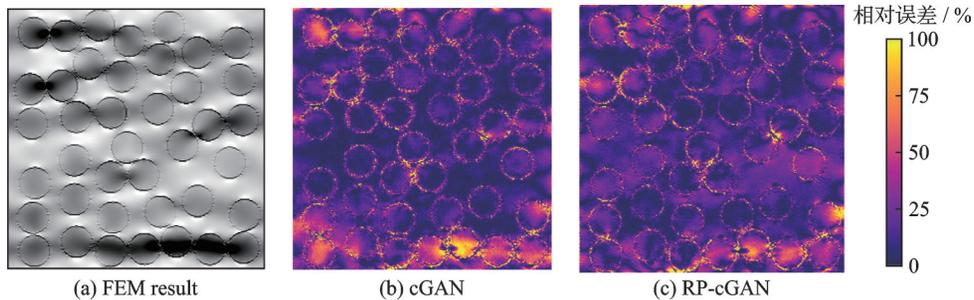


图6 有限元结果及相对误差云图

Fig.6 Typical prediction results and relative error cloud maps

表5为RP-cGAN模型在合并不同载荷工况数据集并增加载荷标签后的预测结果评价。各项指标均表明,该模型对应力云图和应变云图均表现出了优异的预测性能。结构相似指数超过0.98,应力/应变集中区域均方误差小于0.002。通过图7可以看到RP-cGAN模型能够根据输入图像所携

带的载荷标签,输出对应载荷方向的云图。RP-cGAN模型在7s内可对270张图片的云图进行预测,平均26ms便可完成一次云图输出。和传统的有限元建模计算方法相比,RP-cGAN模型既省去了需要针对不同载荷分别建模的繁琐步骤,又有显著的效率提升。

表5 RP-cGAN模型预测应力云图和应变云图的评价结果

Table 5 Evaluation results of stress and strain cloud maps predicted by the RP-cGAN model

云图	MAE	MSE	LPIPS	FID	PSNR	SSIM	C-MSE	GMS
应力	0.018 7	0.000 7	0.006 0	7.230 7	31.718 3	0.987 6	0.001 9	0.997 8
应变	0.015 3	0.000 6	0.001 6	4.006 8	32.572 8	0.983 9	0.000 1	0.999 8

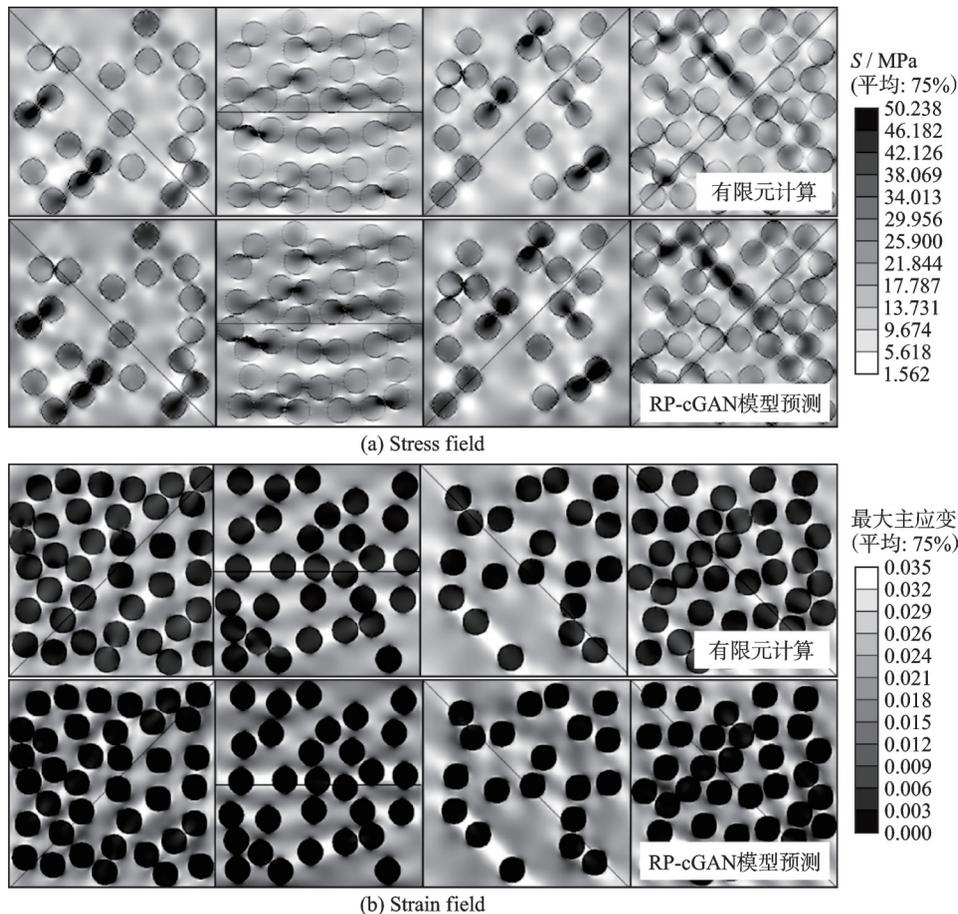


图7 含载荷标签样本的预测云图结果示例

Fig.7 Example of predictive stress/strain cloud map results for labeled payload samples

对于纤维增强材料的微观尺度性能研究,其中损伤起始和损伤扩展是重要的研究分支<sup>[31]</sup>。如图 8 所示,单向纤维增强材料在横向下的损伤形式为界面脱粘和基体开裂<sup>[26]</sup>,在拉伸和剪切条件下

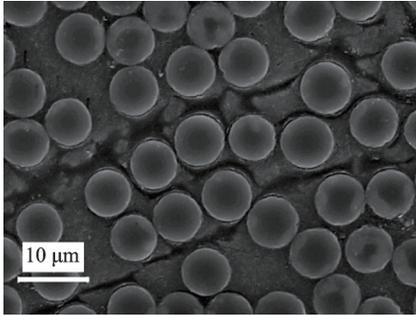


图 8 横向压缩加载下的 AS4/环氧树脂复合材料<sup>[26]</sup>  
Fig.8 AS4/epoxy composite materials under transverse compression loading<sup>[26]</sup>

纤维难以损伤。本研究在上述 T300 纤维增强复合材料的 RVE 线弹性模型基础上,加入 Mises 应力准则和刚度退化,用于输出材料在拉伸载荷作用下的损伤云图。如图 9 所示,模型的损伤起始在纤维间的基体和界面区域,当载荷持续施加时,会形成较为明显的失效带。

利用 RP-cGAN 模型对一组损伤云图特征的学习,可以有效预测随机分布纤维的 RVE 模型的损伤云图。图 10 为 RP-cGAN 模型的典型预测结果和有限元计算结果的对比,表 6 为对 RP-cGAN 模型预测结果的各项评价指标,可以看到 RP-cGAN 模型能够对纤维增强复合材料的横向损伤云图做出准确的预测。同时对纤维密集区和纤维稀疏区的预测均良好,说明模型在纤维体积分数对损伤影响上的预测表现出较好的鲁棒性。

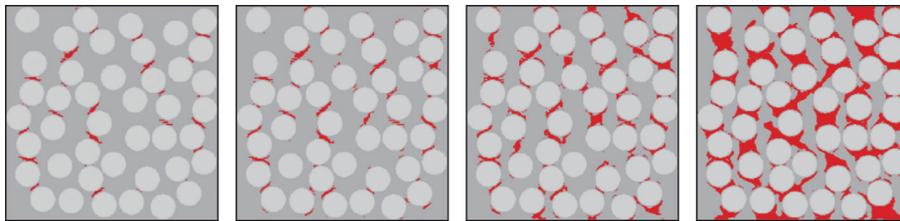


图 9 横向压缩加载下 T300 材料的损伤扩展有限元结果

Fig.9 FEM results of damage propagation in T300 material under transverse compression loading

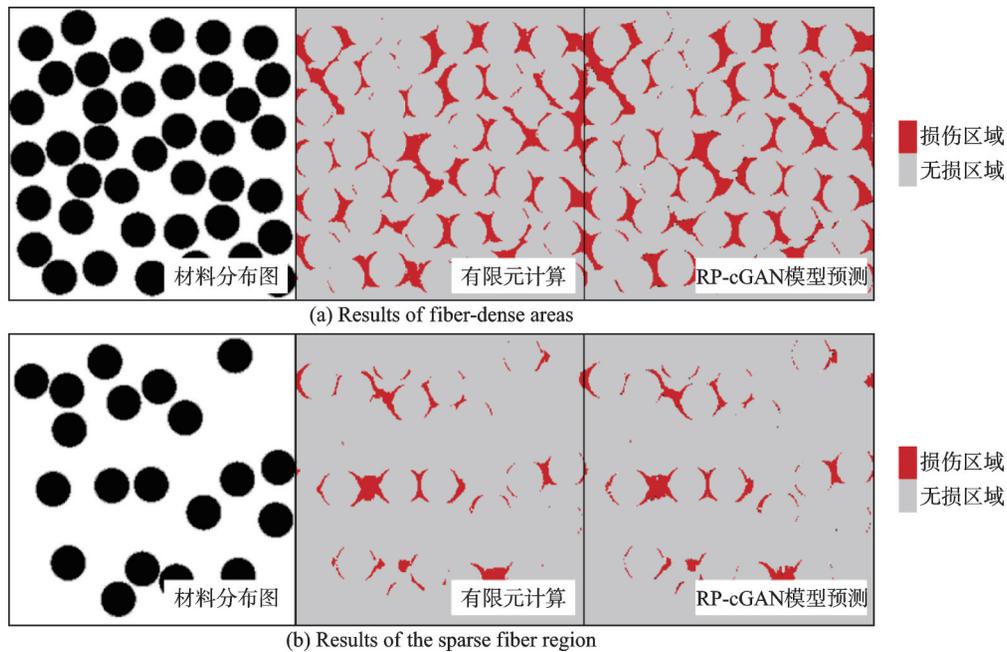


图 10 RP-cGAN 模型对损伤云图的预测和有限元计算对比

Fig.10 Comparison of RP-cGAN model prediction and FEM calculation for damage cloud maps

表 6 RP-cGAN 模型预测损伤云图结果评价

Table 6 Evaluation of damage cloud map prediction results using the RP-cGAN model

云图	MAE	MSE	PSNR	SSIM	C-MSE	GMS
损伤	0.023 7	0.023 4	0.067 8	0.885 0	0.070 6	0.910 4

### 3 结 论

本研究针对纤维增强复合材料微观多场预测中传统有限元方法计算效率低、现有机器学习模型对界面过渡区表征精度不足的问题,提出了一种融

合残差连接与 PixelShuffle 上采样的改进型条件生成对抗网络,并得到以下结论:

(1) RP-cGAN 的架构设计显著提升了预测性能,使界面过渡区的预测误差降低 30%(C-MSE),PixelShuffle 上采样机制则抑制了传统线性采样的棋盘效应,将 PSNR 提升 7%,同时大幅优化了场变量的空间连续性(FID 指标提升 74.87%)。

(2) 模型在 26 ms 内完成单幅云图的准确预测,较传统有限元方法实现计算效率的显著提升。且在不同载荷工况下(拉伸与 $\pm 45^\circ$ 剪切),模型展现出良好的鲁棒性(SSIM > 0.983 9),其生成的应力/应变场在形态学特征与数值分布上与有限元结果高度一致。

(3) 模型对纤维体积分数(20%~60%)的广泛适应性进一步证明了其工程实用价值。在损伤预测扩展应用中,RP-cGAN 成功捕捉了最大应力准则下的刚度退化规律(GMS = 0.910 4),准确表征了损伤萌生于界面过渡区的失效机制,且对纤维密集区与稀疏区的损伤演化均具有一致的预测能力。

本研究为复合材料微观力学响应的预测提供了高效的工具,提出的残差-PixelShuffle 耦合条件生成对抗网络为复杂多场生成任务提供了普适性技术路径。未来研究可进一步探索该模型在三维多尺度失效分析、工艺参数优化及实时健康监测中的应用潜力。

#### 参考文献:

- [1] NAIRN J A. Matrix microcracking in composites [M]//Comprehensive Composite Materials. Amsterdam: Elsevier, 2000: 403-432.
- [2] MIYAGAWA H, MASE T, SATO C, et al. Comparison of experimental and theoretical transverse elastic modulus of carbon fibers[J]. Carbon, 2006, 44(10): 2002-2008.
- [3] SHIOYA M, HAYAKAWA E, TAKAKU A. Non-hookean stress-strain response and changes in crystal-lite orientation of carbon fibres[J]. Journal of Materials Science, 1996, 31(17): 4521-4532.
- [4] REDDY J N. Introduction to the finite element method [M]. 4th ed. New York, USA: McGraw-Hill Education, 2019.
- [5] MORTAZAVI B, BANIASSADI M, BARDON J, et al. Modeling of two-phase random composite materials by finite element, Mori-Tanaka and strong contrast methods[J]. Composites Part B: Engineering, 2013, 45(1): 1117-1125.
- [6] LIU Y M, LIN Q Y, PAN W, et al. SR-M-GAN: A generative model for high-fidelity stress fields prediction of the composite bolted joints[J]. Advanced Engineering Informatics, 2024, 61: 102537.
- [7] VURTUR BADARINATH P, CHERICHETTI M, DAVOUDI KAKHKI F. A machine learning approach as a surrogate for a finite element analysis: Status of research and application to one dimensional systems[J]. Sensors, 2021, 21(5): 1654.
- [8] MEETHAL R E, KODAKKAL A, KHALIL M, et al. Finite element method-enhanced neural network for forward and inverse problems[J]. Advanced Modeling and Simulation in Engineering Sciences, 2023, 10(1): 6.
- [9] ZHANG C, YU J. FEM-constrained neural network-based surrogate model (FCNN-SM) for rapid structural response prediction: Algorithm framework and reliability analysis applications[J]. International Journal of Solids and Structures, 2025, 321: 113556.
- [10] PATHAN M V, PONNUSAMI S A, PATHAN J, et al. Predictions of the mechanical properties of unidirectional fibre composites by supervised machine learning[J]. Scientific Reports, 2019, 9: 13964.
- [11] RAO C P, LIU Y. Three-dimensional convolutional neural network (3D-CNN) for heterogeneous material homogenization[J]. Computational Materials Science, 2020, 184: 109850.
- [12] NIE Z G, JIANG H L, KARA L B. Stress field prediction in cantilevered structures using convolutional neural networks[EB/OL]. (2018-08-27). <https://arxiv.org/abs/1808.08914>.
- [13] BEN BRAYEK B E, SAYED S, MİNZU V, et al. Machine learning predictions for the comparative mechanical analysis of composite laminates with various fibers[J]. Processes, 2025, 13(3): 602.
- [14] KIBRETE F, TRZEPIECIŃSKI T, GEBREMEDHEN H S, et al. Artificial intelligence in predicting mechanical properties of composite materials[J]. Journal of Composites Science, 2023, 7(9): 364.
- [15] YACOUTI M, SHAKIBA M. Performance evaluation of deep learning approaches for predicting mechanical fields in composites[J]. Engineering with Computers, 2024, 40(5): 3073-3086.
- [16] JIANG H L, NIE Z G, YEO R, et al. StressGAN: A generative deep learning model for 2D stress distribution prediction[C]//Proceedings of the 46th Design Automation Conference (DAC). Virtual, Online: American Society of Mechanical Engineers, 2020: V11BT11A023.
- [17] YANG Z Z, YU C H, BUEHLER M J. Deep learning model to predict complex stress and strain fields in hierarchical composites[J]. Science Advances, 2021, 7(15): eabd7416.

- [18] SEPASDAR R, KARPATNE A, SHAKIBA M. A data-driven approach to full-field nonlinear stress distribution and failure pattern prediction in composites using deep learning[J]. *Computer Methods in Applied Mechanics and Engineering*, 2022, 397: 115126.
- [19] GU Y Z, LI M, WANG J, et al. Characterization of the interphase in carbon fiber/polymer composites using a nanoscale dynamic mechanical imaging technique [J]. *Carbon*, 2010, 48(11): 3229-3235.
- [20] NIU Y F, YANG Y, GAO S, et al. Mechanical mapping of the interphase in carbon fiber reinforced poly (ether-ether-ketone) composites using peak force atomic force microscopy: Interphase shrinkage under coupled ultraviolet and hydro-thermal exposure[J]. *Polymer Testing*, 2016, 55: 257-260.
- [21] BU P F, REN H Q, RUAN W J, et al. Calculation method of elastic modulus for carbon fiber-reinforced plastics considering inhomogeneous interphase[J]. *Science and Engineering of Composite Materials*, 2022, 29(1): 452-465.
- [22] HILL R. Elastic properties of reinforced solids: Some theoretical principles[J]. *Journal of the Mechanics and Physics of Solids*, 1963, 11(5): 357-372.
- [23] DRUGAN W J, WILLIS J R. A micromechanics-based nonlocal constitutive equation and estimates of representative volume element size for elastic composites[J]. *Journal of the Mechanics and Physics of Solids*, 1996, 44(4): 497-524.
- [24] GITMAN I M, ASKES H, SLUYS L J. Representative volume: Existence and size determination[J]. *Engineering Fracture Mechanics*, 2007, 74(16): 2518-2534.
- [25] OMAIREY S L, DUNNING P D, SRIRAMULA S. Development of an ABAQUS plugin tool for periodic RVE homogenisation[J]. *Engineering with Computers*, 2019, 35(2): 567-577.
- [26] GONZÁLEZ C, LLORCA J. Mechanical behavior of unidirectional fiber-reinforced polymers under transverse compression: Microscopic mechanisms and modeling[J]. *Composites Science and Technology*, 2007, 67(13): 2795-2806.
- [27] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. *Communications of the ACM*, 2020, 63(11): 139-144.
- [28] NAVAB N, HORNEGGER J, WELLS W M, et al. Medical image computing and computer-assisted intervention[C]//*Proceedings of the 18th International Conference—MICCAI 2015*. Cham: Springer International Publishing, 2015.
- [29] ISOLA P, ZHU J Y, ZHOU T H, et al. Image-to-image translation with conditional adversarial networks [C]//*Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Honolulu, HI: IEEE, 2017.
- [30] SHI W Z, CABALLERO J, HUSZÁR F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network [C]//*Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas, NV, USA: IEEE, 2016: 1874-1883.
- [31] PALIZVAN M, TAHAYE ABADI M, SADR M H. Micromechanical damage behavior of fiber-reinforced composites under transverse loading including fiber-matrix debonding and matrix cracks[J]. *International Journal of Fracture*, 2020, 226(2): 145-160.

(编辑:胥橙庭)