

引文格式: 杨雷, 逢清心, 张佳溪, 等. 基于多任务密集连接网络的复合材料板冰雹冲击定位与能量分级[J]. 航空制造技术, 2026, 69(19): 26020238.

YANG Lei, PANG Qingxin, ZHANG Jiaxi, et al. Hail impact localization and energy classification for composite laminates based on multi-task DenseNet[J]. Aeronautical Manufacturing Technology, 2026, 69(19): 26020238.

基于多任务密集连接网络的复合材料板冰雹冲击定位与能量分级

杨 雷^{1,2}, 逢清心¹, 张佳溪³, 柴万源¹, 朱嘉怡¹, 王子贤¹, 杜鑫宇¹

(1. 大连理工大学力学与航空航天学院, 大连 116024;

2. 江南大学纤维工程与装备技术学院, 无锡 214122;

3. 中国航空工业集团有限公司成都飞机设计研究所, 成都 610091)

[摘要] 针对飞行器复合材料结构的冰雹冲击问题, 构建一种空间约束型多任务密集连接网络(Spatially-constrained multi-task DenseNet, SCMT-DenseNet), 用于实现冲击定位和能量分级。将压电传感器采集的四通道导波信号重构为二维特征图, 采用DenseNet提取深层特征, 并引入空间注意力机制增强关键区域特征表达能力; 设计冲击区域分类、坐标回归和能量分级三支结构, 通过动态高斯软标签、网格图拉普拉斯正则化及坐标先验融合实现空间约束下的联合优化。研究结果表明, 所提方法能够实现对复合材料板上冰雹冲击位置与能量等级的高精度识别, 冲击定位和能量分级准确率分别达到96.1%和99.6%, 且在传感器数量减少情况下仍能保持良好的鲁棒性, 为飞行器复合材料结构的冰雹冲击监测与评估提供了一种有效的技术途径。

关键词: 复合材料结构; 冰雹冲击; 密集连接网络; 冲击定位; 能量分级

中图分类号: V214; V267

文献标志码: A

DOI: 10.16080/j.issn1671-833x.26020238



杨 雷

教授, 博士, 研究方向为复合材料力学与结构健康监测。

碳纤维增强树脂基复合材料凭借高比强度、高比刚度、优异的耐腐蚀性和抗疲劳性能, 已成为现代航空飞行器机身、机翼等关键承力结构的核心材料^[1-2]。在服役过程中, 飞行器不可避免会遭遇冰雹冲击, 这类外源冲击具有强瞬态、高应变率及空间随机性的典型特征^[3]。与金属结构的塑性变形不同, 冰雹冲击易在复合材料内部引发分层、基体开裂、纤维断裂等隐蔽性损伤, 可导致结构压缩承载能力大幅下降, 严重威胁飞行器的飞行安全与结构完整性^[4]。

针对冰雹冲击下复合材料的损

伤演化机理, 国内外学者已开展了大量试验表征与数值模拟研究。Tang等^[5]结合三维数字图像相关技术与有限元数值模拟, 系统分析了铺层方式、纤维/基体类型及冲击参数对复合材料层合板损伤演化的影响规律。Tippmann等^[6]构建了适用于球形冰雹撞击仿真的应变率相关冰材料本构模型, 准确表征了球形冰雹撞击的核心物理机理与现象, 尤其是纵向裂纹的初始萌生、扩展过程, 以及裂纹演化与峰值冲击力形成之间的关联机制。Zhang等^[7]采用GPU加速的光滑粒子流体动力学方法开展冰雹

收稿日期: 2026-06-11; 退修日期: 2026-08-31; 录用日期: 2026-09-01

基金项目: 航空科学基金(20240009063001); 全国重点实验室开放基金(F20250402)

通信作者: 张佳溪, 工程师, 研究方向为飞行器结构设计。

冲击复合材料的数值研究,揭示了冲击速度和冰雹直径对层合板损伤模式的影响规律。上述研究为揭示冰雹冲击损伤机理奠定了坚实基础,但多聚焦于损伤形成过程与失效模式分析,尚未解决服役过程中冰雹冲击事件的实时在线监测与预警问题。

基于超声导波的结构健康监测技术凭借响应速度快、监测范围广等优势,已成为复合材料结构健康监测领域最具应用前景的技术方向之一^[8-9]。其中冲击监测技术能够实时定位冲击源、重构载荷历程并估计冲击能量,对于保障飞行器的服役安全具有重要意义^[10]。近年来,国内外学者在复合材料冲击监测领域取得了显著进展。武湛君等^[11]发展了基于自适应时间反转聚焦的冲击定位方法,该方法可以准确识别加筋复材板上的冲击位置,且在噪声、传感器数量减少和变温情况下仍然具有较好的精度。白生宝等^[12]提出了基于粒子群优化算法的复合材料板结构冲击定位算法,该算法在保证冲击定位精度的同时降低了计算成本。汪英等^[13]开发了一种MXene/CNT柔性薄膜传感器阵列,结合改进的三角定位算法,实现了对复合材料冲击位置的高精度识别。Deng等^[14-17]针对复合材料平板及加筋板提出了冲击定位的系列方法,这些方法实现了高精度的冲击定位,并可同时识别冲击位置

和冲击能量。

此外,深度学习技术凭借强大的自适应特征提取能力,突破了传统信号处理方法依赖人工设计特征的局限,已成为冲击监测领域的重要技术手段。Zargar等^[18]构建了卷积神经网络(Convolutional neural network, CNN)-循环神经网络(Recurrent neural network, RNN)混合架构,结合时间反转物理原理,实现了对铝板结构的高精度冲击定位。Chen等^[19]提出了时空协同特征学习框架,通过交替堆叠CNN与双向长短期记忆网络模块,有效降低了平均定位误差。Zhao等^[20]构建了一种基于特征提取的深度学习冲击监测模型,引入域对抗迁移学习策略,提取源域与目标域之间的域不变特征,有效降低了训练样本的需求量。Xiao等^[21]提出一种物理机理结合数据驱动的混合冲击定位算法,分别在复合材料平板与加筋板上开展落锤撞击试验,定位结果表明,该混合算法仅需极少冲击训练样本即可保证高效、精准的定位效果。

然而,上述研究多采用刚性球自由下落或摆锤撞击作为模拟冲击源,其力学特性与冰雹冲击存在本质差异。与刚性冲击物不同,冰雹在撞击复合材料结构表面时可能发生破碎,冲击过程中接触刚度持续变化,载荷作用时间延长,且部分冲击能量随冰

球碎裂而耗散,导致现有基于刚性冲击源开发的监测方法在冰雹冲击场景下的定位与能量评估性能显著下降。针对这一问题,本文提出一种面向复合材料板冰雹冲击定位与能量分级的空间约束型多任务密集连接网络(Spatially-constrained multi-task DenseNet, SCMT-DenseNet),通过压电传感器网络采集复合材料板上冰球不同冲击位置与能量下的波动响应信号,建立冲击样本库,以DenseNet为主干网络提取深层特征,并设计冲击区域分类、坐标回归和能量分级三支结构,实现对冰球冲击位置和能量等级的联合识别。

1 冰球冲击试验

冰雹的大小对复合材料的冲击响应具有重要影响,一般将最大直径 ≥ 20 mm的冰雹界定为强冰雹事件^[22]。综合考虑可获得性与低速冲击损伤可重复性,选取直径为20 mm的冰球作为冲击体。如图1所示,试验件为尺寸500 mm $\times$ 500 mm的碳纤维复合材料编织板,铺层方式为 $[0/90]_6$,总厚度为2 mm。将4枚直径为8 mm的圆形压电传感器(型号PZT-5H)分别粘贴于距板边界70 mm处。以传感器围成的360 mm $\times$ 360 mm区域作为有效监测区域,并将其均匀划分为81个(9 $\times$ 9)边长为40 mm的网格区域,按照1号传感器到4号传




图1 复合材料板实物图及监测区域示意图

Fig.1 Physical photograph of composite plate and schematic diagram of monitoring area

传感器的顺序编号为1~81号区域。

冲击试验过程中,对复合材料板的两边采用夹持方式进行固定,以保证冲击条件的一致性,如图2所示。为获得不同冲击能量下的响应信号,采用PVC导向管控制冰球下落轨迹,并在末端连接测速仪,监测冰球冲击的瞬时速度。分别在1 m、1.5 m和2 m高度释放冰球,对81个网格区域进行冲击试验。冲击信号由大连君晟科技有限公司生产的被动式信号采集系统记录,采样频率为200 kHz,采样时间为5 ms。每个冲击区

域在各高度条件下重复试验10次,共获得2430组冲击信号样本,每组样本包含4个通道各1000个采样点的数据。

冰球采用统一型号的模具制备,质量为3.84 g,理想情况下由重力势能公式可以计算获得冰球冲击速度及能量。然而,由于冰球下落过程中不可避免地与导向管管壁发生摩擦,引发能量耗散,因此试验中采用测速仪测量冰球冲击瞬间速度,进而计算冰球真实冲击能量。试验发现,同一高度下冰球冲击速度存在一定随机

性,但速度区间相对集中,不同名义高度下冰球冲击的平均速度及能量均值如表1所示。随着下落高度增加,能量损耗的比例逐渐增大,这是因为更高的高度下,冰球与管壁的碰撞概率变大,但总体上冲击能量仍保持着随冲击高度增加而逐步增大的趋势。根据冲击高度对应的能量水平,将样本划分为低、中、高3个能量等级区间,用于后续冲击定位与能量分级模型的训练和测试。

为分析冰球冲击响应信号的时间域特征,选取典型冲击区域(25号区



图2 复合材料板冰球冲击试验装置

Fig.2 Ice sphere impact test apparatus for the composite plate

表1 不同高度下冰球理论冲击速度及能量与实际情况对比

Table 1 Comparison of ideal impact velocity and energy of ice spheres with experimental data under various drop heights

冲击高度/m	理论速度/(m/s)	理论能量/mJ	实际速度均值/(m/s)	实际能量均值/mJ	平均能量耗散率/%
1.0	4.43	37.6	4.15	33.1	12
1.5	5.42	56.5	4.97	47.4	16
2.0	6.26	75.3	5.49	58.0	23

域)在不同冲击高度下的四通道响应信号进行说明,如图3所示。冰球冲击复合材料板后,各传感器通道均出现明显的瞬态电压响应,信号在初始峰值之后呈现阻尼振荡衰减特征,说明冲击能量以波动形式在板内传播,并在传播过程中受到材料阻尼、边界反射和波型转换等因素影响。不同冲击高度下的信号波形具有相似的整体形态,但幅值水平随冲击高度增加而增大,靠近冲击区域的传感器通道通常表现出更强的瞬态响应。上述信号特征表明,冰球冲击响应同时包含与冲击能量相关的幅值信息和与冲击位置相关的空间传播信息,从而为后续构建多任务深度学习模型提供了物理依据。

2 模型与方法

本研究构建的 SCMT-DenseNet 整体架构如图4所示。该网络以四

通道导波信号重构得到的二维特征图为输入,采用 DenseNet 提取深层特征,并设置冲击区域分类、坐标回归和能量分级3个任务分支进行联合学习。为增强定位结果的空间连续性,在多任务优化过程中引入空间约束机制,实现冲击位置与能量等级的协同预测。

2.1 信号预处理与主干特征提取

2.1.1 信号预处理

试验采集到的四通道导波信号每通道采样点数为1000,对每通道信号进行零填充处理,统一调整至1024个采样点,并将调整后的一维序列重构为 32×32 的二维特征图,使其符合卷积网络的输入形式。值得注意的是,这种邻接关系仅作为二维卷积运算中的特征关联形式,并不赋予其实际的物理空间含义。全部样本均采用相同的重构方式,因此网络所接收的特征表示具有一致性,且卷

积网络并非依赖单一采样点之间的邻接关系进行判别,而是通过多层卷积对局部响应、幅值变化及跨片段组合特征进行综合学习。因此,该重构方式不会改变模型对冲击信号整体特征的学习目标。

由于信号幅值与冲击能量密切相关,在利用归一化方法统一输入信号幅值尺度,提高网络稳定性和收敛效率的同时,应保留不同能量等级间的幅值差异信息,因此利用训练集全体数据计算全局均值和标准差,并将其应用于训练集和测试集的零均值单位方差归一化:

$$\hat{F}_{in} = \frac{F_{in} - \mu_F}{\sigma_F + \varepsilon} \quad (1)$$

式中, F_{in} 和 $\hat{F}_{in}$ 分别为归一化前和归一化后的输入; μ_F 和 σ_F 分别为训练集全体元素的均值和标准差; $\varepsilon=10^{-6}$ 为防止除零的数值稳定项。




图3 25号区域不同高度下的冲击响应信号

Fig.3 Impact response signals of Area 25 at different impact heights

2.1.2 DenseNet主干网络

主干网络采用密集连接结构 (Dense Block) 作为特征提取的基本单元。区别于传统残差网络仅将前一层输出与当前层输出相加的方式, Dense Block 将前序所有层的输出沿通道维度拼接后共同作为当前层的输入, 第 l 层的输出为

$$x_l = H_l([x_0, x_1, \dots, x_{l-1}]) \quad (2)$$

式中, x_l 为第 l 个密集层的输入特征图; $[x_0, x_1, \dots, x_{l-1}]$ 表示第 0 层至第 $l-1$ 层输出沿通道维度的拼接结果; $H_l(\cdot)$ 为第 l 层的复合变换函数, 由批归一化 (BN)、ReLU 激活函数和 3×3 卷积依次构成。

设增长率为 g , 经过 n 个密集层后, Dense Block 的输出通道数为

$$C_{out} = C_{in} + n \cdot g \quad (3)$$

式中, C_{out} 和 C_{in} 分别为输出和输入通道数。设置 $g=16$, 每个 Dense Block 含 4 个密集层。这种密集连接机制充分复用了浅层特征, 有效缓解了深层网络中的梯度消失问题, 在小数据集情况下具有更好的泛化能力。

在相邻两个 Dense Block 之间插入过渡层, 用于压缩通道数并降低特征图空间分辨率:

$$T(x) = \text{AvgPool}_{2 \times 2} \left\{ \text{Conv}_{1 \times 1} \left\{ \text{ReLU} \left[\text{BN}(x) \right] \right\} \right\} \quad (4)$$

式中, $T(x)$ 为过渡层输出; x 为过渡层输入特征图; $\text{Conv}_{1 \times 1}$ 为 1×1 卷积, 用于通道压缩; $\text{AvgPool}_{2 \times 2}$ 为步长为 2 的平均池化, 用于空间下采样。

网络共设置 3 个级联的 Dense Block, 主干网络输入通道由初始 3×3 卷积映射至 32 通道, 经 3 个 Dense Block 及 2 个过渡层后, 主干网络最终输出特征图通道数为 192, 如图 5 所示。

2.1.3 空间注意力模块

导波在复合材料板中传播时, 冲击点与各传感器的距离不同, 导致特征图中响应能量的空间分布不均。为使网络自适应地聚焦于含有冲击信息的关键空间位置, 在主干网络末端引入空间注意力模块 (Spatial attention module, SAM)。该模块以

完全自监督的方式学习空间显著性权重, 无须额外标注信息, 计算开销小的同时特征增益显著。

沿通道维度分别计算主干输出特征图 F 的均值响应映射与最大值响应映射, 将二者拼接后经 7×7 卷积与 Sigmoid 激活函数生成二维空间注意力权重图 M_s :

$$M_s = \sigma \left(\text{Conv}_{7 \times 7} \left([A_{avg}; A_{max}] \right) \right) \quad (5)$$

式中, σ 为 Sigmoid 激活函数; A_{avg} 和 A_{max} 均为空间注意力计算的中间映射。

注意力增强后的特征图 F' 为

$$F' = F \otimes M_s \quad (6)$$

2.2 多任务输出头设计

冲击定位与能量分级虽同源于导波响应信号, 但二者关注的特征属性存在差异。冲击定位主要依赖于导波传播过程中的时空分布特征, 而能量分级更关注信号幅值变化及能量分布特征。若完全共享特征表示, 可能导致任务间信息竞争, 从而影响各任务的优化效果。为兼顾特征共享与任务特异性表达, 设计了冲击区




图4 空间约束型多任务密集连接网络整体框架
Fig.4 Overall framework of the SCMT-DenseNet




图5 SCMT-DenseNet主干网络结构

Fig.5 Backbone network architecture of the SCMT-DenseNet

域分类、坐标回归和能量分级3条并行输出分支。

对于定位分支和坐标回归分支,首先对注意力增强特征图 F' 执行全局平均池化,将空间维度压缩为一维特征向量,减少参数量的同时降低过拟合风险。其中,定位分支通过全连接网络输出81个区域的分类概率,提供离散化的区域级定位结果。而坐标回归分支与定位分支共享特征向量,输出冲击网格的二维坐标估计,并在推理阶段为定位分支提供空间先验约束。

能量分级分支采用相对独立的特征提取路径,通过卷积层和自适应平均池化进一步提取与冲击能量相关的判别特征,最终输出低、中、高三级能量等级。该设计在保留主干网络共享信息的同时,增强了能量分级任务的特征表达能力。

三条任务分支在统一的多任务损失函数约束下进行联合训练,在充分利用共享特征的基础上实现任务专属特征学习,从而提升冲击定位与能量分级的整体性能。

2.3 多任务联合损失函数

与传统区域分类任务不同,冰雹冲击定位具有明显的空间拓扑特征,相邻冲击区域之间存在连续的空间邻域关系。当预测结果偏离真实位置时,其误差应尽可能限制在邻近区域内,以保证定位结果的空间合理性。为此,在定位任务中引入空间约束机制,通过动态高斯软标签编码区域间的空间邻近关系,利用网格图拉

普拉斯正则化约束预测概率分布的空间平滑性,并结合坐标回归分支构建坐标先验融合策略,从而将空间信息嵌入网络训练与推理过程。基于上述设计,构建包含定位损失、能量分级损失、坐标回归损失及空间正则项的多任务联合损失函数。

2.3.1 动态高斯软标签

传统硬标签完全忽略了冲击位置的空间邻域信息,易导致模型在相邻区域间的判别边界过于生硬,造成边界区域样本的梯度信号不稳定。为此,提出高斯软标签策略,将冲击区域的空间邻域关系显式编码至监督标签中。

对于真实冲击区域 $k(k=0,1,\dots,80)$,任意网格坐标 (i,j) 处的标签权重由以目标区域为中心的高斯函数给出:

$$\tilde{p}_{i,j}^{(k)} = \exp\left(-\frac{(i-x_k)^2 + (j-y_k)^2}{2\sigma_g^2}\right), \quad i,j \in (0,1,\dots,8) \quad (7)$$

式中, $\tilde{p}_{i,j}^{(k)}$ 为网格坐标 (i,j) 处的未归一化标签权重; x_k, y_k 为真实冲击区域 k 的网格坐标; σ_g 为高斯函数的标准差,控制标签分布的弥散程度。经归一化处理,得到满足概率分布约束的81维软标签向量 $q^{(k)}$ 。

固定 σ_g 值存在两难困境:较大的 σ_g 有助于训练初期的梯度传播和模型泛化,但会导致训练后期分类边界模糊;较小的 σ_g 则使训练初期的优化路径不稳定。为兼顾两方面需求,对 σ_g 实施指数退火策略,随训练轮次 t

的增加逐步降低标签的弥散程度:

$$\sigma_t = \max(\sigma_{\min}, \sigma_0 \cdot \gamma^t) \quad (8)$$

式中, σ_t 为第 t 个训练轮次所使用的高斯标准差;初始标准差 $\sigma_0=1.0$;指数衰减系数 $\gamma=0.95$;标准差下限 $\sigma_{\min}=0.3$,以防止标签过度集中。在测试阶段使用 $\sigma_{\text{test}}=0.3$,使评价标准接近硬标签预测,保证测试指标的严格性。

2.3.2 网格图拉普拉斯正则化

仅依赖定位任务的Kullback-Leibler (KL)散度损失,网络预测的概率分布可能在空间上呈现不连续跳变,与导波在复合材料板中传播的物理规律相悖。为此,将 9×9 网格视为无向图 $G=(V,E)$,其中 V 为包含81个节点的集合,每个节点对应一个冲击区域。若两区域互为8邻域,则在对应节点间建立边,构成集合 E 。图的拉普拉斯矩阵定义为

$$L = D - A \quad (9)$$

式中, L 为图拉普拉斯矩阵; D 为度矩阵,表示节点的邻居节点数量; A 为邻接矩阵,用于判别两节点是否为8邻域。

对于预测概率向量 p ,图正则化损失 L_{graph} 定义为

$$L_{\text{graph}} = E[p^T L p] = \left[\sum_{(i,j)} A_{i,j} (p_i - p_j)^2 \right] \quad (10)$$

式中, p_i 和 p_j 分别为节点 i 与节点 j 对应的预测概率; E 表示对样本取均值。图正则化损失对空间相邻区域间概率差异的平方进行惩罚,促使预测概率分布在网格空间上呈现平滑连

续的形态。

为避免训练初期图正则化约束干扰主任务优化,对其权重采用线性预热策略:

$$\lambda_{\text{graph}}^{(t)} = \min(\lambda_{\text{max}}, \lambda_0 + \Delta\lambda \cdot t) \quad (11)$$

式中, $\lambda_{\text{graph}}^{(t)}$ 为第 t 个训练轮次的图正则化权重;初始权重 $\lambda_0 = 0.05$;每轮次线性增量 $\Delta\lambda = 0.003$;权重上限 $\lambda_{\text{max}} = 0.2$ 。

2.3.3 总损失函数与坐标先验融合推理

综合定位 KL 散度损失、能量分级交叉熵损失、坐标回归均方误差 (MSE) 损失与图正则化损失,多任务联合总损失函数 L 为

$$L = \underbrace{D_{\text{KL}}(\mathbf{q} \parallel \mathbf{p})}_{L_{\text{loc}}} + \underbrace{\frac{1}{2} \left(-\frac{1}{N} \sum_{n=1}^N \log \frac{e^{z_{\text{enc}}}}{\sum_{m=0}^2 e^{z_{\text{enc}}}} \right)}_{L_{\text{enc}}} + \underbrace{\lambda_{\text{coord}} \frac{1}{N} \sum_{n=1}^N \left\| \hat{\mathbf{c}}^{(n)} - \mathbf{c}^{(n)} \right\|_2^2}_{L_{\text{coord}}} + \lambda_{\text{graph}}^{(t)} L_{\text{graph}} \quad (12)$$

式中, L_{loc} 为定位任务的 KL 散度损失; L_{enc} 为能量分级任务的交叉熵损失; N 为批内样本数; z_{enc} 表示样本真实能量等级对应的逻辑值;能量等级索引 $m \in (0, 1, 2)$; L_{coord} 为坐标回归任务的均方误差损失; $\hat{\mathbf{c}}^{(n)}$ 和 $\mathbf{c}^{(n)}$ 分别为第 n 个样本的预测归一化坐标和真实归一化坐标;坐标回归损失的权重系数 $\lambda_{\text{coord}} = 0.15$ 。

在测试推理阶段,利用坐标回归输出 $\hat{\mathbf{c}}$ 反归一化后得到网格坐标 $(\hat{x}_{\text{grid}}, \hat{y}_{\text{grid}})$,并以此为中心构造高斯空间先验:

$$\pi_{i,j} = \exp \left(-\left(i - \hat{x}_{\text{grid}} \right)^2 + \left(j - \hat{y}_{\text{grid}} \right)^2 / 2\sigma_p^2 \right) \quad (13)$$

式中, $\pi_{i,j}$ 为以预测坐标为中心的网格位置 (i,j) 处的未归一化先验概率;

先验高斯函数的标准差 $\sigma_p = 0.7$,控制先验分布的聚焦范围。归一化后与定位分支预测概率线性融合,最终预测冲击区域为

$$\hat{k} = \arg \max_k [(1-\alpha) p_k + \alpha \pi_k] \quad (14)$$

式中, $\hat{k}$ 为最终预测的冲击区域编号;先验融合权重 $\alpha = 0.25$,使定位分类概率保持 75% 的主导权重。

当定位分支在相邻区域间输出概率接近时,空间先验有效引导决策向几何上更合理的位置倾斜,从而提升邻域命中率与整体定位精度;而在定位分支置信度较高时,先验项对最终结果影响甚微。

3 结果与讨论

基于冰球冲击试验获取的数据集,对所提 SCMT-DenseNet 进行系统性能评估。首先,通过冲击定位准确率、平均空间误差及能量分级准确率等指标,评估网络在冲击位置识别和能量等级预测任务中的性能,验证模型的有效性。随后,设计消融试验,对比说明所提出的深度学习网络中各个模块的作用,并将 SCMT-DenseNet 与常见网络模型进行对比,验证所提方法在复合材料板冰雹冲击定位及能量分级任务中的优势。最后,开展不同传感器通道缺失条件下的对比试验,进一步验证模型在传感器数量受限场景下的鲁棒性和适用性。

3.1 网络性能评估

为了验证 SCMT-DenseNet 的有效性,首先对模型性能进行评估。对于试验所得的样本,本研究采取分层抽样的方式,按照 8:2 的比例划分为训练集和测试集,以保证划分后的两个数据集内的类分布与原始数据集保持一致,避免随机划分可能带来的类不平衡问题,从而保证模型泛化能力评估的公平性和可靠性。最终训练集样本数为 1944,测试集样本数为 486。训练轮次设置为 60 轮,训练过程中的损失曲线如图 6 所示。




图6 模型训练过程的损失曲线

Fig.6 Loss curves during model training process

训练初期,模型损失下降较快,说明网络能够快速学习导波信号中与冲击位置及冲击能量相关的主要特征;随着训练轮次增加,训练损失和测试损失均逐渐趋于稳定,二者在后期保持较小差距,表明模型具有较好的收敛性和泛化能力。由于动态高斯软标签的影响,测试损失在第 24 轮出现小幅波动,但整体下降趋势明显,未出现持续增大的过拟合现象,说明所构建的多任务网络能够较稳定地完成冲击定位与能量分级联合优化。

为了更加直观地表征模型性能,引入准确率 (Accuracy)、召回率 (Recall)、F1 score 3 个分类任务中衡量模型性能的常用指标对模型进行评估。准确率衡量所有样本之间的正确分类率;召回率衡量模型对真实正样本的检出能力;F1 score 是精确率与召回率的调和平均值,用于综合评价模型的性能。对于本文的多分类任务,使用平均召回率和平均 F1 score 衡量模型分类性能。

$$\text{Accuracy} = \frac{N_{\text{TP}} + N_{\text{TN}}}{N_{\text{TP}} + N_{\text{TN}} + N_{\text{FP}} + N_{\text{FN}}} \quad (15)$$

$$\text{Recall}_{\text{macro}} = \frac{1}{K} \sum_{k=1}^K \frac{N_{\text{TP}_k}}{N_{\text{TP}_k} + N_{\text{FN}_k}} \quad (16)$$

$$F_{\text{macro}} = \frac{1}{K} \sum_{k=1}^K \frac{2 \cdot \text{Precision}_k \cdot \text{Recall}_k}{\text{Precision}_k + \text{Recall}_k} \quad (17)$$

其中,

$$\text{Precision}_k = \frac{N_{\text{TP}_k}}{N_{\text{TP}_k} + N_{\text{FP}_k}} \quad (18)$$

式中,以冲击定位任务为例,定位区域

类别数 $K=81$; N_{TP} 、 N_{FP} 、 N_{TN} 、 N_{FN} 分别表示真正例、假正例、真负例和假负例; Precision_k 表示第 k 个区域的预测精确率。

对于冲击定位任务, 486 个测试集样本中, 仅有 19 个样本定位出错, 准确率为 96.1%, 平均召回率达到 96.1%, 平均 F1 score 达到 96.1%, 表明网络能够较为准确地识别各冲击区域样本, 并在分类准确性与类别覆盖能力之间保持良好的平衡。较高的召回率说明大部分真实冲击样本能够被正确识别, 而较高的 F1 score 则表明模型在不同区域间具有稳定的分类性能, 未出现明显的类别偏置现象。对于能量分级任务, 486 个测试集样本中, 仅有 2 个样本判断出错, 准确率达 99.6%, 平均召回率为 99.6%, 平均 F1 score 为 99.6%。3 个指标数值保持一致, 说明模型在保持高检出率的同时, 并未出现明显的类别偏置或误分类集中现象。

进一步采用混淆矩阵对网络性能进行分析, 图 7 给出了冲击定位任务和能量分级任务的混淆矩阵。在冲击定位任务中, 混淆矩阵的主要响应集中在主对角线位置, 说明大部分测试样本能够被正确分类至对应冲击区域, 仅有少量非对角线元素存在响应, 且这些误判大多分布在真实冲击区域的邻近位置, 表明模型即使在未完全命中真实区域时也能够保持较好的空间邻域一致性。该结果说明, 动态高斯软标签、图拉普拉斯正则化和坐标先验融合策略能够有效引导网络学习冲击区域之间的空间连续关系, 降低远距离误判的概率。在能量分级任务中, 混淆矩阵的主要响应集中于低、中、高三个能量等级对应的主对角线位置, 非对角线区域响应很少, 说明模型对 3 类冲击能量均具有较高的识别准确率。

为进一步评估空间约束机制的有效性, 确保错误样本落在真实样本相邻区域, 引入平均空间误差指标,

公式为

$$d_e = \frac{1}{N} \sum_{i=1}^N \sqrt{(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2} \quad (19)$$

式中, N 为测试集误分类样本数; x_i 、 y_i 为第 i 个样本的真实横、纵坐标; $\hat{x}_i$ 、 $\hat{y}_i$ 为第 i 个样本的预测横、纵坐标。结果表明, 模型预测错误样本平均空间误差为 1.14 个网格边长, 说明大部分误分类样本落在真实样本相邻区域, 表现出空间约束机制的有效性。

3.2 消融试验

为证明所提改进方法的有效性, 在相同数据集划分方式下, 基于 SCMT-DenseNet 开展消融试验, 分别去除网络中空间注意力模块、高斯软标签、图拉普拉斯约束和坐标回归分支, 重新对模型进行训练和测试, 预测结果如图 8 所示。

结果表明, 去除不同模块时, 网络性能出现不同程度的下降。其中, 缺失高斯软标签对网络性能影响最大, 定位准确率下降至 76.9%, 相比之下, 去除图拉普拉斯约束后定位准确率下降幅度较小, 但其对定位误差分布仍具有明显影响。高斯软标签和图拉普拉斯约束的主要作用不仅限于提高定位准确率, 更重要的是引入空间邻近关系, 引导模型在出现误

判时优先将样本预测至真实区域的邻近区域, 以降低空间定位误差。去掉高斯软标签和图拉普拉斯约束后, 最大定位误差从 3.0 格分别增大至 7.6 格和 5.0 格, 说明二者较好地实现了空间约束。此外, 去除空间注意力模块和坐标回归分支后, 模型性能也出现一定程度下降, 但下降幅度相对较小。空间注意力模块主要用于增强特征图中与冲击识别相关的判别性响应, 抑制冗余特征干扰; 坐标回归分支则通过引入网格中心坐标标签, 为网络提供辅助空间位置约束。由于最终定位结果主要由定位分支给出, 当定位分支置信度较高时, 坐标回归分支对最终区域识别结果的直接影响相对有限。综合来看, 各模块在定位准确率、定位误差控制和特征表达增强方面发挥了不同作用, 完整 SCMT-DenseNet 的性能提升来源于多模块的协同作用。

3.3 不同网络模型性能对比

为进一步验证所提方法的优越性, 在相同数据集划分及试验设置条件下, 将 SCMT-DenseNet 与 Transformer、图神经网络(Graph neural network, GNN) 和时序卷积网络(Temporal convolutional network, TCN) 等典型网络模型进行了对比, 结果如图 9 所示。为保证对比结果的公平性, 所有基准模型均引入与本




图 7 冲击定位与能量分级任务的混淆矩阵

Fig.7 Confusion matrix for impact localization and energy level classification




图8 缺失不同模块时的网络性能对比
Fig.8 Comparison of network performance when different modules are missing




图9 不同网络模型性能对比
Fig.9 Performance comparison of different network models

文相同的空间约束机制。

结果表明,SCMT-DenseNet在冲击定位任务中取得了最高的定位准确率,其性能明显优于Transformer (91.1%)、GNN (93.4%) 和 TCN (83.5%),同时具有最低的平均空间误差。相比 Transformer 和 GNN, SCMT-DenseNet能够通过密集连接结构实现特征复用与多尺度信息融合,有效缓解深层网络训练过程中信息衰减的问题;相比TCN,其因二维特征建模能力,更适合挖掘导波信号重构图中的局部相关特征。此外,构建的三支多任务学习框架能够同时利用区域分类、坐标回归和能量分级任务之间的互补信息,实现更充分的特征共享与协同优化。上述结果表明,所提 SCMT-DenseNet 不仅能

够有效利用空间约束信息,而且在特征提取与多任务联合学习方面具有明显优势。

3.4 传感器通道数量减少条件下性能分析

在实际应用环境中,传感器布设可能受到结构空间、工程条件等因素限制。为评估模型在传感器数量减少条件下的适用性,进一步开展了三通道传感器组合试验。具体而言,在4个压电传感器的通道中每次去除1个通道,仅利用剩余3个通道的信号对网络模型进行训练和预测,共形成4种三通道组合。结果如图10所示。可以发现,在任意三通道组合情况下,模型的定位准确率仍保持在93.1%~94.7%,能量分级准确率保持在97.9%~99.2%,相比四通道输入条

件,仅出现有限下降。这一结果表明,所提 SCMT-DenseNet 模型在传感器布设受限等实际工况下仍能够保持较高的监测精度,具有良好的工程应用前景。

4 结论

本文提出了一种空间约束型多任务密集连接网络,通过构建冲击区域分类、坐标回归和能量分级三任务协同学习框架,并引入空间约束机制增强定位结果的空间连续性,实现了复合材料板冰球冲击位置与能量等级的准确识别。主要结论如下:

(1) SCMT-DenseNet在复合材料板冰球冲击监测任务中表现出优异性能,其所构建的空间约束多任务学习框架能够有效提升冲击定位和能




图10 缺失不同通道时网络性能对比

Fig.10 Comparison of network performance with different channels missing

量分级准确率,在尺寸为500 mm × 500 mm的碳纤维复合材料板上采用4枚传感器的冲击定位准确率为96.1%,能量分级准确率达99.6%。

(2)消融试验显示,在分别缺少空间注意力模块、高斯软标签、图拉普拉斯约束及坐标回归分支的情况下,网络性能出现不同程度的下降,表明各模块在定位准确率、定位误差控制和特征表达增强方面发挥了不同作用,完整 SCMT-DenseNet 的性能提升来源于多模块的协同作用。

(3)在相同数据集和试验条件下,与 Transformer、GNN 和 TCN 等基准模型相比,SCMT-DenseNet 取得了更高的定位准确率和更低的平均空间误差,表明多任务协同学习与 DenseNet 特征复用机制能够更充分地挖掘导波信号中的空间判别特征,从而提升冲击监测性能。

(4)在仅使用3枚传感器的条件下,模型定位准确率仍保持在93.1%以上,能量分级准确率保持在97.9%以上,表明所提方法对传感器数量减少的场景仍具有较好的泛用性,具有良好的工程应用潜力。

参考文献

[1] 张卫红,唐长红. 航空航天装备的轻量化: 挑战与未来[J]. 航空学报, 2024, 45(5): 529965.

Zhang Weihong, Tang Changhong. Lightweighting of aerospace and aeronautical equipment: Challenges and perspectives[J]. Acta Aeronautica et Astronautica Sinica, 2024, 45(5): 529965.

[2] 张国庆,滕超逸. 航空航天先进结构材料技术现状及发展趋势[J]. 航空材料学报, 2024, 44(2): 1-12.

Zhang Guoqing, Teng Chaoyi. Current status and development trend of advanced structural materials technology in aerospace field[J]. Journal of Aeronautical Materials, 2024, 44(2): 1-12.

[3] 白春玉,赵子豪,刘小川,等. 飞机结构抗冰雹冲击特性研究进展与展望[J]. 航空学报, 2025, 46(21): 532424.

Bai Chunyu, Zhao Zihao, Liu Xiaochuan, et al. Research progress and prospects in hail impact resistance of aircraft structures[J]. Acta Aeronautica et Astronautica Sinica, 2025, 46(21): 532424.

[4] Ren M N, Wang Y F, Cheng D H, et al. Numerical analysis for damage characteristics in composite laminates under multiple hail particles impacts[J]. International Journal of Solids and Structures, 2025, 323: 113489.

[5] Tang Z B, Hang C, Suo T, et al. Numerical and experimental investigation on hail impact on composite panels[J]. International Journal of Impact Engineering, 2017, 105: 102-108.

[6] Tippmann J D, Kim H, Rhymer J D. Experimentally validated strain rate dependent material model for spherical ice impact simulation[J]. International Journal of Impact Engineering, 2013, 57: 43-54.

[7] Zhang W, Yu W L, Chen J Y, et al.

Numerical modeling of damage mechanism in CFRP plates under high-velocity hail impact using a strain-rate dependent model[J]. Engineering Analysis with Boundary Elements, 2026, 186: 106701.

[8] Yang Z Y, Yang H J, Tian T, et al. A review on guided-ultrasonic-wave-based structural health monitoring: From fundamental theory to machine learning techniques[J]. Ultrasonics, 2023, 133: 107014.

[9] 田童,李建乐,邓德双,等. 飞行器结构健康监测技术研究进展[J]. 航空制造技术, 2024, 67(13): 41-67, 98.

Tian Tong, Li Jianle, Deng Deshuang, et al. Research progress of structural health monitoring technology for aircraft[J]. Aeronautical Manufacturing Technology, 2024, 67(13): 41-67, 98.

[10] 曾旭,邓德双,杨红娟,等. 航空结构低速冲击监测技术研究进展[J]. 航空学报, 2024, 45(23): 030368.

Zeng Xu, Deng Deshuang, Yang Hongjuan, et al. Research progress in low-velocity impact monitoring technology for aircraft structures[J]. Acta Aeronautica et Astronautica Sinica, 2024, 45(23): 030368.

[11] 武湛君,曾旭,邓德双,等. 基于自适应时间反转聚焦的加筋复材板冲击定位[J]. 复合材料学报, 2024, 41(1): 507-520.

Wu Zhanjun, Zeng Xu, Deng Deshuang, et al. Impact localization on stiffened composite plate based on adaptive time reversal focusing[J]. Acta Materiae Compositae Sinica, 2024, 41(1): 507-520.

[12] 白生宝,邓德双,张阳,等. 基于粒子群优化算法的复合材料板结构冲击定位[J]. 兵器装备工程学报, 2025, 46(11):

197–205.

Bai Shengbao, Deng Deshuang, Zhang Yang, et al. Impact localization on composite plate structure based on particle swarm optimization algorithm[J]. Journal of Ordnance Equipment Engineering, 2025, 46(11): 197–205.

[13] 汪英, 卢少微, 张璐. 基于MXene/CNT薄膜传感器阵列的复合材料冲击定位及损伤监测[J]. 航空制造技术, 2024, 67(13): 92–98.

Wang Ying, Lu Shaowei, Zhang Lu. Impact localization and damage monitoring of composite materials based on MXene/CNT thin film sensor array[J]. Aeronautical Manufacturing Technology, 2024, 67(13): 92–98.

[14] Deng D S, Zeng X, Yang Z Y, et al. Multi-frequency probabilistic imaging fusion for impact localization on aircraft composite structures[J]. Structural Health Monitoring, 2025, 24(1): 185–201.

[15] Deng D S, Zeng X, Yang Y, et al.

Data fusion based impact localization on aircraft composite structures using Bayesian estimation and weighted averaging[J]. Mechanical Systems and Signal Processing, 2025, 230: 112675.

[16] 邓德双, 曾旭, 杨正岩, 等. 基于贝叶斯估计和数据融合的复合材料结构冲击定位[J]. 仪器仪表学报, 2024, 45(5): 251–261.

Deng Deshuang, Zeng Xu, Yang Zhengyan, et al. Impact localization of composite structures based on Bayesian estimation and data fusion[J]. Chinese Journal of Scientific Instrument, 2024, 45(5): 251–261.

[17] Deng D S, Zeng X, Pang Q X, et al. Simultaneous impact localization and energy estimation in composite structures using ensemble learning and approximate Bayesian computation[J]. Thin-Walled Structures, 2026, 225: 114754.

[18] Zargar S A, Yuan F G. Impact diagnosis in stiffened structural panels using a

deep learning approach[J]. Structural Health Monitoring, 2021, 20(2): 681–691.

[19] Chen T, Guo L, Duan A, et al. A feature learning-based method for impact load reconstruction and localization of the plate-rib assembled structure[J]. Structural Health Monitoring, 2022, 21(4): 1590–1607.

[20] Zhao B W, Qing X L, Wang Y S, et al. Impact monitoring based on domain adversarial transfer learning strategies[J]. Smart Materials and Structures, 2025, 34(3): 035017.

[21] Xiao D, Sharif-Khodaei Z, Aliabadi M H. Hybrid physics-based and data-driven impact localisation for composite laminates[J]. International Journal of Mechanical Sciences, 2024, 274: 109222.

[22] Li X F, Zhang Q H, Zou T, et al. Climatology of hail frequency and size in China, 1980 – 2015[J]. Journal of Applied Meteorology and Climatology, 2018, 57(4): 875–887.

Hail Impact Localization and Energy Classification for Composite Laminates Based on Multi-Task DenseNet

YANG Lei^{1,2}, PANG Qingxin¹, ZHANG Jiayi³, CHAI Wanyuan¹, ZHU Jiayi¹, WANG Zixian¹, DU Xinyu¹

(1. School of Mechanics and Aerospace Engineering, Dalian University of Technology, Dalian 116024, China;

2. School of Fiber Engineering and Equipment Technology, Jiangnan University, Wuxi 214122, China;

3. AVIC Chengdu Aircraft Design & Research Institute, Chengdu 610091, China)

[ABSTRACT] Aiming at the hail impact issue of aircraft composite structures, a spatially-constrained multi-task DenseNet (SCMT-DenseNet) is constructed to realize impact localization and energy classification. The four-channel guided wave signals collected by piezoelectric sensors are reconstructed into two-dimensional feature maps, and DenseNet is adopted to extract deep-level features. A spatial attention mechanism is embedded to strengthen the feature representation capability of critical regions. A three-branch architecture is designed for impact area classification, coordinate regression and energy grading. Joint optimization under spatial constraints is accomplished by means of dynamic Gaussian soft labels, grid graph Laplacian regularization and coordinate prior fusion. The experimental results demonstrate that the proposed method can achieve high-precision identification of hail impact positions and energy levels on composite plates. The accuracy of impact localization and energy grading reaches 96.1% and 99.6%, respectively. Moreover, favorable robustness can be maintained even when the number of sensors is reduced. This work provides an effective technical route for hail impact monitoring and evaluation of aircraft composite structures.

Keywords: Composite structure; Hail impact; DenseNet; Impact localization; Energy classification

(责编 青燕)