

基于多尺度融合的蜂窝复合材料缺陷检测网络

马敏, 马小雯

(中国民航大学 电子信息与自动化学院, 天津 300300)

摘要: 针对航空蜂窝板复合材料外部蒙皮破损导致内部产生泥沙、积水以及裂纹等影响飞行安全的问题, 提出采用电容层析成像技术 (ECT, electrical capacitance tomography) 进行蜂窝板复合材料缺陷检测; 针对平面 ECT 成像精度低的问题, 通过构建多尺度融合策略、残差编码解码融合模块, 引入一种新的池化模块 (Soft-pool) 等形成多尺度残差编码解码路径的深层神经网络 (Ms RED, multi-scale residual encoding and decoding paths), 使最终的结果完全融合解码阶段学到的特性, 对使用共轭梯度成像算法的重建图像进一步改善; 结果表明, 应用平面 ECT 技术可以实现蜂窝材料的缺陷检测, 通过 Ms RED 网络可以提升图像重建效果, 更清晰重建出蜂窝结构缺陷图像。

关键词: 蜂窝复合材料; 无损检测; 电容层析成像; 多尺度融合; 图像重建算法

Defect Detection Network of Honeycomb Composites Based on Multi-scale Fusion

MA Min, MA Xiaowen

(College of Electronic Information and Automation, China Civil Aviation University, Tianjin 300300, China)

Abstract: In order to solve the problems that the flight safety is affected by internal sediment, stagnant water and cracks caused by the damage of the outer skin of aeronautical honeycomb panels, electrical capacitance tomography (ECT) is proposed to detect the defects of honeycomb composite materials. In order to solve the problem of low accuracy of planar ECT imaging, by constructing multi-scale fusion strategy, residual coding and decoding fusion module, and introducing a new pooling module to form a deep neural network of multi-scale residual coding and decoding path, the final result is fully integrated with the characteristics learned in the decoding stage, and the reconstructed image using conjugate gradient imaging algorithm is further improved. The results show that the defect detection of honeycomb materials can be realized by using planar ECT technology, and the image reconstruction effect can be improved by multi-scale fusion honeycomb composite defect detection network, and the defect image of honeycomb structure can be reconstructed more clearly.

Keywords: honeycomb composites; non-destructive testing; electrical capacitance tomography; multi-scale fusion; image reconstruction algorithms

0 引言

随着现代复合材料和制造工艺技术的不断发展, 以碳纤维、芳纶纤维、玻璃纤维等高性能纤维制成的材料得到了越来越广泛地运用^[1]。蜂窝复合材料以其优异的性能得以迅速发展, 因具有高抗压性、低变形、耐腐蚀、优良的电绝缘性能, 能够减轻飞行器结构质量, 提高飞行器隔热性能, 因而被广泛应用于航空航天、国防工业等领域。蜂窝复合材料主要由三部分组成, 蜂窝材料的上下表面蒙皮 (一般为树脂或碳纤维材质), 内部的蜂窝夹芯层 (一般为芳纶纸粘合而成), 用来结合表面蒙皮和蜂窝芯的胶层。常见损伤包括脱粘、基体开裂、进水和冲击损伤, 常见的损伤检测方法有红外成像法、X 射线检测、声阻法等。红外成像法借助对热红外敏感的特点对物体进行成像, 常用于

蜂窝复合材料是否进水的检测, 但受周围环境温度影响很大; X 射线检测的检测结果虽然准确可靠, 但设备庞大, 费用高, 且对人体有伤害^[3]; 声阻法检测构建冲击损伤操作简单, 但检测效率和判伤/类型不够灵敏, 具有一定局限性。常规无损检测存在检测盲区、检查效率差、检测成像效果差等缺点。因此, 本文首次提出基于电容层析成像技术对航空蜂窝复合材料进行缺陷检测。其检测原理是通过测量获得一组电容值, 再根据计算得到的电容值求取介质的介电常数分布。当蜂窝复合材料内部有损伤缺陷时, 电极板产生的电场线会发生扭曲, 电容传感器可以由此检测到电学信号的变化, 再通过电容层析成像算法重构图像^[4]。

1 平面 ECT 系统检测原理

平面阵列 ECT 传感器各极片在电压激励下的电场线分

收稿日期: 2021-04-12; 修回日期: 2021-05-10。

基金项目: 国家自然科学基金委员会与中国民用航空局联合资助项目(U1733119); 民航科技项目(20150220)。

作者简介: 马敏(1971-), 女, 安徽霍邱人, 硕士生导师, 教授, 主要从事无损检测技术及新型传感器方向的研究。

引用格式: 马敏, 马小雯. 基于多尺度融合的蜂窝复合材料缺陷检测网络[J]. 计算机测量与控制, 2021, 29(11): 41-47, 60.

布是均匀的,如图 1 所示,当电极片相对时电场线为平行线,当电极片在同一平面上时电场线呈“开口状”分布,电场分布因电极片的分布变化而改变,这种现象称作电容的边缘效应。平面阵列 ECT 即根据电容的边缘效应进行基本的复合材料检测。

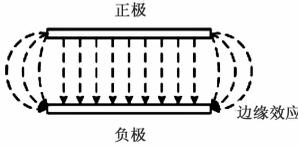


图 1 电容的边缘效应示意图

检测原理如图 2 所示。通常情况下,电容的边缘效应被认为检测工作过程中的一个干扰因素,ECT 技术是对电容的边缘效应的利用,并逐步发展为一种新型的无损检测手段。

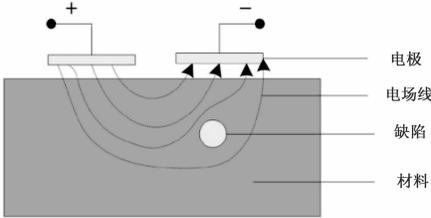


图 2 电容的边缘效应检测原理

根据待测场介质排列和分布的不同和初始边界条件,将已测得的因复合材料缺陷产生的介质变化情况转换为电极对间的电容值序列。

通过高斯通量定律得电极板 i, j 之间的电容值 $C_{i,j}$:

$$C_{i,j} = \frac{Q}{V} = \frac{1}{V} \iint_D \epsilon_{i,j}(x,y) \nabla \varphi_{i,j}(x,y) dS \quad (1)$$

式 (1) 中, $\varphi_{i,j}(x,y)$ 表示电场分布情况, Q 表示极板间的电荷值, $\epsilon_{i,j}(x,y)$ 表示被测场域的介质分布, V 表示两电极板之间的电势差值。

对于数目为 N 的电极阵列,首次单循环对 1 号电极进行激励,剩下的 $N-1$ 个电极依次获取接收信号,第二次单循环激励以 2 号电极为激励电极,剩余的 $N-2$ 个极板接收信号,循环上述操作^[5]。对于 16 电极传感器得到独立测量电容值数据个数为 120。

1.1 蜂窝复合材料建模过程

首先创建三维模型向导,运用模型开发器中的几何工具和零件绘制一个三维蜂窝复合材料的模型,设置蜂窝夹层的介电常数为 1.069 5,蜂窝表面蒙皮树脂材料介电常数为 4.0。

如图 3 所示蜂窝复合材料板的尺寸设置为 100 mm × 100 mm × 12 mm,中间蜂窝芯的高度为 8 mm,上下表面蒙皮厚度均为 1 mm,蜂窝芯与蒙皮之间的胶层厚度均为 1 mm。

在材料的上表面胶层的中心位置绘制一个半径为 10 mm 圆柱缺陷,模拟此处受到冲击损伤缺陷。如图 4 所示。

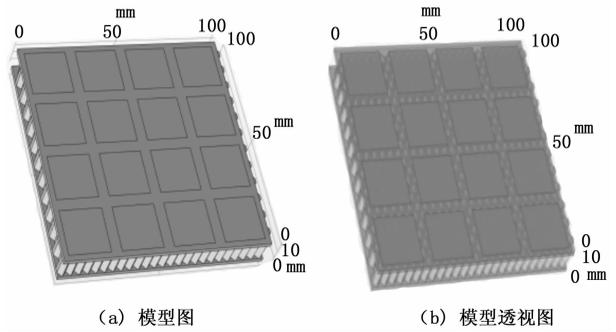


图 3 蜂窝复合材料模型图

敏感场的准确性会伴随有限元的剖分网格数的增加和减少产生变化,一般细化网格数会增加精确度,但是细化会占用很多的内存造成资源浪费,计算时间也会随之变得 longer。该模型较为简单,可以根据物理场控制网格划分对网格进行常规剖分即可,如图 5 所示。

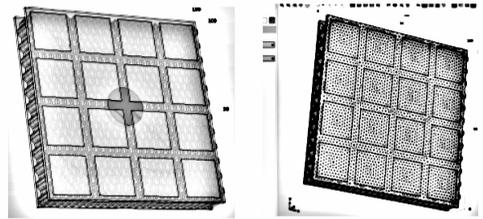


图 4 缺陷透视图 图 5 网格剖分图

系统检测数据的来源是平面阵列电容传感器,因此传感器的性能对数据的准确性至关重要。为了使传感器精度更高,实验为传感器设置了极间屏蔽、边缘屏蔽和底部屏蔽。因为平面阵列电容传感器的边缘电场很微弱,为了使测量数据更精确避免外界噪声干扰,如图 6 所示添加极间屏蔽和边缘屏蔽的电势分布,图 7 所示为添加屏蔽的传感器模型,每个电极对之间设置了宽度为 1 mm 的极间屏蔽和边缘屏蔽,为了使测量数据更精确避免外界噪声干扰,在传感器底部设置 10 mm × 10 mm 的底部屏蔽。

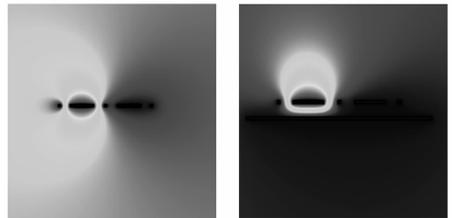
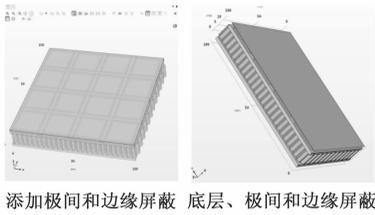


图 6 添加屏蔽的电场线变化

1.2 数据归一化

在 ECT 系统中电容值信号比较微弱,且传感器不同位置的电容值会相差很多数量级,相距较近的电极对间电容值远远大于相距较远的电极对,为解决 ECT 系统中电容值数量级相差过大的问题,在研究中将得到的电容数值和灵敏度矩阵^[6]进行归一化处理,以减少电容差别对于图像准确性产生的干扰。电容的归一化公式为:



添加极间和边缘屏蔽 底层、极间和边缘屏蔽

图 7 添加屏蔽的传感器仿真模型

$$C = \frac{C_{obj} - C_{emp}}{C_{ful} - C_{emp}} \quad (2)$$

式 (2) 中, C_{emp} 表示不放置材料即被测区域为空气时的电容值即空场电容值, C_{ful} 表示检测材料完整无缺陷时测得的电容值即满场电容值, C_{obj} 表示缺陷材料的被测电容值即物场电容值。灵敏度矩阵处理过程如下:

$$S_{i,j}^*(e) = \frac{S_{i,j}(e)}{\sum_{k=1}^N S_{i,j}(k)} \quad (3)$$

式 (3) 中, $S_{i,j}(e)$ 表示归一化之前的电极对 $i-j$ 之间的第 e 个单元的灵敏度, $S_{i,j}^*(e)$ 为归一化后的电极对 $i-j$ 之间第 e 个单元的灵敏度。

2 图像重建算法

首先通过传统算法对仿真模型进行图像重建结果及分析, 为构建损伤分类模型选取合适的算法^[7]。基于 COM-SOL Multiphysics 5.3 有限元仿真软件构造不同的缺陷类型, 在 MATLAB 编译相关的图像重建算法进行成像。根据损伤位置和损伤大小将缺陷类型定义为双矩形、中心圆形、复杂类型 3 种, 其中双矩形缺陷尺寸为 $1.5 \text{ cm} \times 1.5 \text{ cm}$, 中心圆形缺陷半径为 1.5 cm , 复杂形损伤的矩形缺陷尺寸为 $1.5 \text{ cm} \times 1.5 \text{ cm}$ 、中心圆形缺陷半径为 1.5 cm 。根据图像重建的结果, 如表 1 所示, 结合图像重建评价标准分析不同算法的成像效果。

表 1 不同算法对蜂窝复合材料重建图像仿真对比

缺陷类型			
LBP 算法			
Newton-Raphson 算法			
共轭梯度算法			

从表 1 中可以得出, LBP 和共轭梯度算法的成像效果比 Newton-Raphson 算法成像效果好, 能够准确地反映出简单缺陷所在的位置和大小, Newton-Raphson 算法在平面电容层析成像的失真和伪影现象都比较严重。共轭梯度算法的成像效果与 LBP 算法较相似, 实验仿真能够清晰地显示出简单缺陷信息。

选取图像相关系数 (CORR, correlation coefficient) 和图像相对误差 (IME, image error) 作为图像重建效果的评价标准定量评价图像重建的效果, 公式如下:

$$C_{CORR} = \frac{\sum_{i=1}^m (\hat{G}_i - \bar{G})(G_i - \bar{G})}{\sqrt{\sum_{i=1}^m (\hat{G}_i - \bar{G})^2 \sum_{i=1}^m (G_i - \bar{G})^2}} \quad (4)$$

$$I_{IME} = \frac{\|\hat{G} - G\|}{\|G\|} \quad (5)$$

式中, G 是被测场域内的介电常数分布, \hat{G} 为图像重建结果, \bar{G} 和 $\bar{\hat{G}}$ 分别为 G 和 \hat{G} 的平均值。 C_{CORR} 越大, 表示重建结果与真实分布的相关程度越大, 重建图像越接近原始图像, 当 C_{CORR} 趋近于 1 时, 能够说明重建图像的空间分布率比较高, 图像的质量较好。 I_{IME} 越小, 表示重建结果与真实分布的误差越小, 成像的效果越好^[8]。

根据图像重建的评价标准, 计算出图像相关系数和图像相对误差。通过不同算法针对蜂窝复合材料重建图像仿真, LBP 算法针对缺陷类型一的图像相关系数为 0.674 4, 针对缺陷类型二的图像相关系数为 0.706 2, 针对缺陷类型三的图像相关系数为 0.643 5, 平均图像相关系数为 0.674 7; Newton-Raphson 算法针对缺陷类型一的图像相关系数为 0.422 3, 针对缺陷类型二的图像相关系数为 0.416 8, 针对缺陷类型三的图像相关系数为 0.310 4, 平均图像相关系数为 0.383 2; 共轭梯度算法针对缺陷类型一的图像相关系数为 0.785 5, 针对缺陷类型二的图像相关系数为 0.713 4, 针对缺陷类型三的图像相关系数为 0.634 7, 平均图像相关系数为 0.711 2。对比柱如图 8 所示。

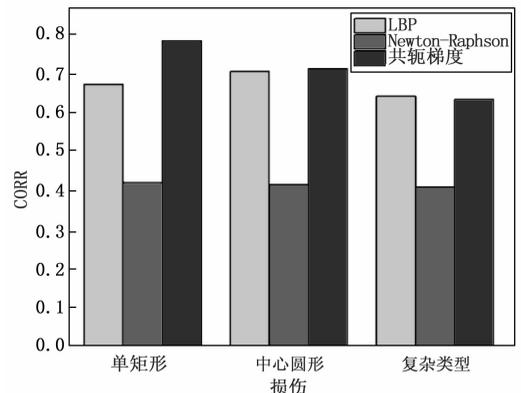


图 8 图像相关系数对比柱

LBP 算法针对缺陷类型一的图像相对误差为 0.327 5, 针对缺陷类型二的图像相对误差为 0.295 4, 针对缺陷类型三的图像相对误差为 0.365 7, 平均图像相对误差为

0.329 5; Newton-Raphson 算法针对缺陷类型一的图像相对误差为 0.585 7, 针对缺陷类型二的图像相对误差为 0.515 6, 针对缺陷类型三的图像相对误差为 0.542 5, 平均图像相对误差为 0.547 9; 共轭梯度算法针对缺陷类型一的图像相对误差为 0.316 5, 针对缺陷类型二的图像相对误差为 0.270 8, 针对缺陷类型三的图像相对误差为 0.344 2, 平均图像相对误差为 0.310 5。对比柱如图 9 所示。

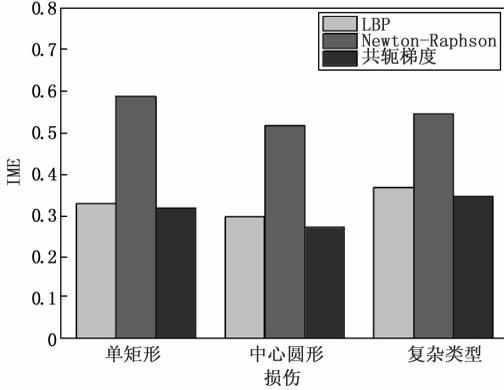


图 9 图像相对误差对比柱

通过数据对比可以得到共轭梯度算法的平均图像相关系数最高, 平均图像相对误差最小, 整体看来, 共轭梯度算法的成像效果较好。因此在后续损伤分类模型构建中, 使用共轭梯度算法进行成像。

3 基于多尺度融合深层神经网络

针对传统平面电极电容层析成像技术可以为复合材料检测技术提供依据, 但有精度不高、对比度低等缺陷。为此提出一种基于多尺度残差编码解码路径的深层神经网络 Ms RED (multi-scale residual encoding and decoding paths), 使用多分支卷积层 MCL (multi-branch convolution layer) 来提取特征, 使用多尺度残差编码融合模块 MsR-EFM (multi-scale residual encoding fusion module) 来融合编码特征, 使用多尺度残差解码融合模块 MsR-DFM (multiscale residual decoding fusion module) 反映了多尺度残差译码路径, 引入卷积注意力模块 (CBAM, convolutional block attention module) 来捕获远程多通道的依赖关系和有效利用空间特征表示, 将一种新的池化模块 (Soft-pool) 引入到复合材料缺陷检测网络中, 该模块能够在降采样时保留更多的信息, 并获得更丰富的特征, 多尺度残差编码译码网络 (Ms RED) 总体框架如图 10 所示。使最终的结果完全融合每一层在解码阶段学到的特性, 实现融合解码特征, 实现 ECT 的图像重建。

3.1 多尺度融合策略

传统卷积神经网络在信息传递过程中总会存在信息丢失、信息损耗、梯度消失、梯度爆炸等问题, 多尺度可以通过对信号的不同粒度进行采样解决此类问题^[9]。通常, 为了完成不同的任务, 可以在不同的尺度上观察到不同的

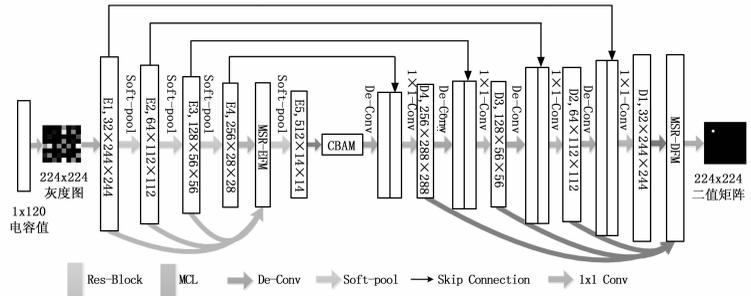


图 10 多尺度残差编码译码网络 (Ms RED) 总体框架

特征。目标尺寸的巨大变化是影响模型性能的主要因素, 极小或极大的目标将显著降低模型的性能, 当接收场较小时, 只能观察到目标的局部特征。当接收野较大时, 大量无用的信息会混入视野中。卷积神经网络一层层地提取目标特征, 随着层次的加深, 神经网络的接受野逐渐增加^[10]。因此, 多尺度模型体系结构在近年来备受关注。其结构可以分为多尺度输入、多尺度特征融合、多尺度特征预测融合^[11], 以及这 3 种结构的组合。目前有两种常见的多尺度特征融合网络。第一种是并联多分支网络, 第二种是串行跳层连接结构。它们都提取了不同感受野的特征。多尺度特征融合首先根据不同尺度的特征对目标进行预测, 然后将预测结果进行融合。

3.2 多尺度残差编码融合模块 MsR-EFM

为了使网络在编码阶段能够完全学习数据的上下文特征^[12], 设计了多尺度残差编码融合模块 MsR-EFM, 与其他采用元素相加或连接的方式融合多尺度特征的方法不同^[13], 本文提出的 MsR-EFM 能够自适应地学习不同编码级别的特征权重^[14]。MsR-EFM 包括两个步骤: 相同缩放和自适应融合。结构如图 11 所示。

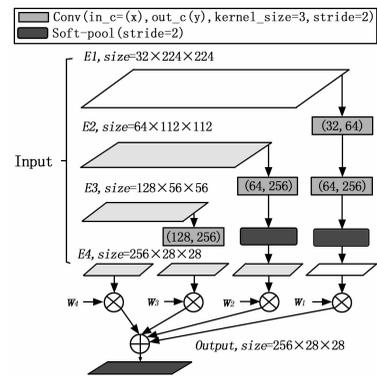


图 11 多尺度残差编码融合模块结构模型

相同尺度变化: 将编码器中 $l(l \in \{1, 2, 3, 4\})$ 的特征表示为 X_l , 对应图 10 中的 E1、E2、E3、E4。由于不同层次的特征具有不同的分辨率和通道, 所以在融合前必须先要将它们统一成相同的形状^[15]。我们使用 X'_m 来表示将特征 X_m 的大小调整为特征 X_l 的大小的操作。使用步长为 2 的卷积核与步长为 2 的 Soft-pool 来重新缩放特征, 从而统一 E1、E2、E3 到 E4 的最小分辨率和最大通道。使用 f_l 表示

步长为 2 的卷积核, f_p 表示步长为 2 的 Soft-pool。对不同大小的编码特征进行缩放的具体操作如下:

$$\begin{aligned} X_1^4 &= f_p(f_c(f_c(X_1))) \\ X_2^4 &= f_p(f_c(X_2)) \\ X_3^4 &= f_p(X_3) \\ X_4^4 &= X_4 \end{aligned} \quad (6)$$

自适应融合: X_m^l 表示将第 n 级特征缩放到第 l 级特征大小的操作。定义如下:

$$Y_{MSR-EFM} = \omega_1 \cdot X_1^l + \omega_2 \cdot X_2^l + \omega_3 \cdot X_3^l + \omega_4 \cdot X_4^l \quad (7)$$

其中: l 为 4, $\omega_1, \omega_2, \omega_3, \omega_4$ 为可训练参数, 表示通过缩放得到的特征的权值, 可以是简单的标量变量, 它们可以在所有通道中共享。 $\omega_1 + \omega_2 + \omega_3 + \omega_4 = 1$ 并且 $\omega_1, \omega_2, \omega_3, \omega_4 \in [0, 1]$ 。 ω_n 定义为:

$$\omega_n = \frac{e^{\lambda_n}}{e^{\lambda_1} + e^{\lambda_2} + e^{\lambda_3} + e^{\lambda_4}} \quad (8)$$

其中: $n \in \{1, 2, 3, 4\}$ 。分别以 $\lambda_1, \lambda_2, \lambda_3, \lambda_4$ 为控制参数的 Soft-max 函数定义 $\omega_1, \omega_2, \omega_3, \omega_4$, 可以通过标准反向传播学习。

3.3 卷积注意力模块 CBAM

本文引入卷积注意力模块 CBAM, 利用通道注意块和空间注意块两种注意模块来增强分类间的识别能力和响应能力^[16], 进一步将局部特征与全局特征相关性结合, 有效利用多通道空间进行特征表示和非特征化, 是网络更有效地针对损伤进行分类。空间注意模块通过所有空间位置的加权特征选择性地聚合每个空间位置的特征, 使得模型能够捕获特征的远程依赖关系, 如图 12 所示。

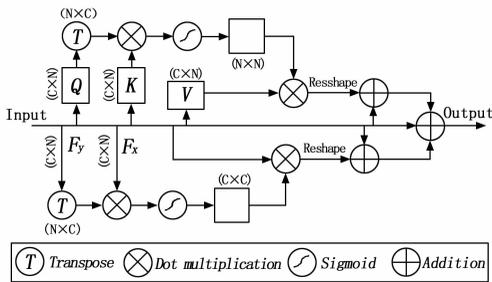


图 12 注意力机制模块结构模型

注意力机制模块中使用了卷积、批归一化、反卷积。CBAM 的结构为输入输出大小为 $C \times H \times W$, 其中 C 表示输入特征的维数, H 和 W 分别是输入图像的高度和宽度, 本网络中使用的是 $512 \times 14 \times 14$ 。 $N = H \times W$ 表示的是特征数量。 Q 和 K 的转置应用 Soft-max 层可以得到类内空间关联。由于一个高级特征的每个通道都可以看作是一个特定类的相应, 通过空间注意块来改进特征表示。

3.4 多尺度残差解码融合模块 MsR-DFM

在编译码网络中, 不同层次的接收域不同, 所接收到的信息也不同。为了充分融合解码器中不同级别的信息, 获得更可信的分割结果, 本文提出了 MsR-DFM, 如图 13

所示。

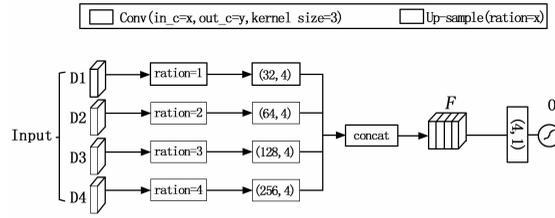


图 13 多尺度残差解码融合模块结构模型

MsR-DFM 通过多重池和多重注意融合不同层次的特征。我们将解码器的 l 级特征记为 $Y_l (l \in \{1, 2, 3, 4\})$, 对应图 8 中的 D1, D2, D3 和 D4。 Y_l 的分辨率为 224×224 , 与网络的输入分辨率相同。 Y_l' 表示将特征 Y_l 调整为特征 Y_1 大小的操作。该操作是通过和 3×3 卷积来实现的。双线性插值变换法定义为 f_u 将 Y_l 的分辨率提高到 Y_1 的分辨率, 使用多重注意融合定义为 f_c 将重新采样特征的通道压缩到 4 个, 计算量更少。对不同大小的解码特征^[17]进行缩放的具体操作见式 (8)。经过缩放, 4 个特征的形状统一为 $4 \times 224 \times 224$ 。将它们通过 Concat 函数连接起来形成 F 见式 (9)。

$$Y_l' = f_c(f_u(Y_l, 2^{l-1})), l \in \{1, 2, 3, 4\} \quad (9)$$

$$F = \text{Concat}(Y_1', Y_2', Y_3', Y_4') \quad (10)$$

3.5 多分支卷积层 MCL

为了增强网络提取更丰富层次特征的能力, 在每个分支中使用多层卷积。使用不同内核的多分支池, 如图 14 所示。

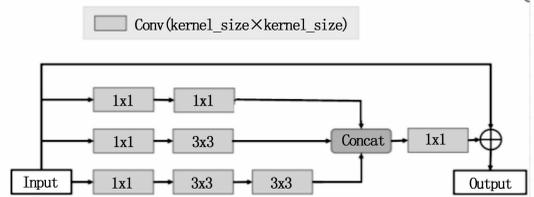


图 14 多分支卷积层结构模型

该结构由 1×1 卷积和 $n \times n (n \in \{1, 3, 5\})$ 卷积组成。前者用于压缩特征通道, 减少计算量。后一种卷积被 $1 \times n$ 卷积和 $n \times 1$ 卷积所取代, 以减少参数的数量。为了进一步减少参数, 增强更深层次的非线性, 引用两个堆叠的 3×3 卷积, 增强了模块的特征提取能力^[18]。然后, 使用 1×1 的卷积来融合和细化这些层次特征, 以生成最终的表示。

3.6 Soft-pool

常用的池方法包括平均池和最大池, 但是这两种方法都有一定缺点。平均池化平均降低了该区域内所有数值的效果, 而最大池化仅选择该区域内单个特征激活最高的特征激活。与它们不同的是, 基于 Softmax 加权方法来保留输入的基本属性, 同时放大更大强度的特征激活。根据特征值非线性地计算区域 R 的特征值权重。权重 w_i 能够保证重要特征的传递, 区域 R 内的特征值在反向传递时都至少会有预设的最小梯度。在得到权重 w_i 后, 通过加权区域 R

内的特征值得到输出。它可以累加指数加权激活，并更好地保留信息特征。Soft-pool 的作用介于这两种池化方法之间，它所有激活都对最终的输出有贡献，较高的激活比较低的激活占主导地位，这可以平衡平均池和最大池的影响。Soft-pool 利用激活内核内的最大近似区域 R ($|R| = k \times k, k = 2$)。每个激活 a_i 指数应用 i 的权重计算的自然指数的比率，激活所有激活的自然指数 R ，然后 \hat{a} 输出值是通过一个激活 R 的加权总和得到的：

$$\hat{a} = \sum_{i \in R} \frac{e^{a_i}}{\sum_{j \in R} e^{a_j}} \times a_i \quad (11)$$

Soft-Pool 是可微的，在反向传播计算时，Soft-Pool 梯度根据前向时的激活值比例进行计算，若梯度过小，将直接赋予预设的非零最小梯度值。Soft-Pool 能够很好的保留特征表达，是最大池化和平均池化两者有利属性的折中。Soft-pool 池化对矩阵的扩展过程如图 15 所示。

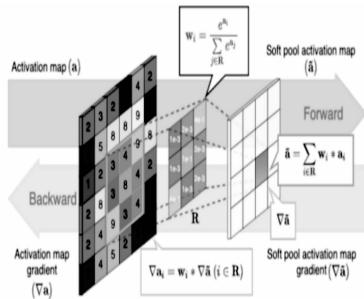


图 15 Soft-pool 池化对矩阵的扩展过程

3.7 损失函数

所有数据集都包含完整的标注，在二维图像中对损伤的分割可以看作是一个像素级的二值分类任务：损伤还是材料。在本网络中，采用二进制交叉熵 (BCE) 损失作为网络训练的目标函数。二进制交叉熵公式表示为：

$$L_{BCE} = -\frac{1}{N} \sum_{i=1}^N g_i \cdot \log(p_i) + (1 - g_i) \cdot \log(1 - p_i) \quad (12)$$

其中： $g_i \in \{0, 1\}$ 和 $p_i \in \{0, 1\}$ 分别表示注释和概率映射， N 表示像素个数。最终训练过程的损失函数曲线如图 16 所示。

3.8 训练过程

具体实现分为以下几个步骤。

步骤一：首先，配置 PyTorch 运行环境，在平台上建立 Ms RED 模型；

步骤二：获取 ECT 图像样本集，利用共轭梯度算法进行反演，将 1×120 一组的电容值转换为 224×224 一组的灰度值；

步骤三：训练样本为的 2 000 组不同位置、不同大小不同形状的损伤模型特征，其中 1 600 组为训练组，400 组为测试组，训练过程设置的 Batch_size 为 64。

步骤四：将训练好的网络模型用于检测测试集 ECT 数据，分析测试结果。

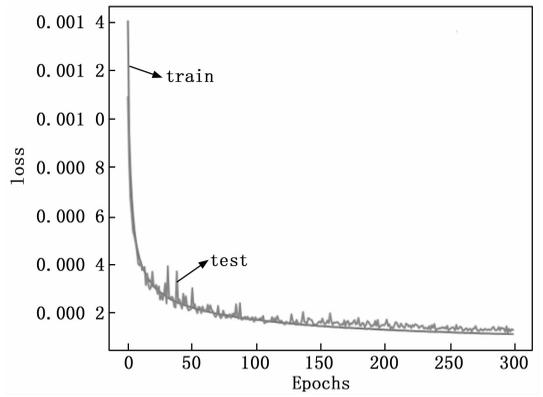


图 16 损失函数

4 检测结果与分析

4.1 模型评价指标

为了评价网络中各个模块，进行不同模块的消融实验。基线：选择 CS2-Net^[19] 为模型基础上完成网络结构的设计。模型一：使用多分支卷积层替换 CS2-Net 中的编码解码模块。模型二：在模型一的基础上添加多尺度残差编码融合模块。模型三：在模型一的基础上添加多尺度残差解码融合模块。模型四：在模型一的基础上添加多尺度残差编码融合模块和多尺度残差解码融合模块。模型五：在模型四的基础上添加 Soft-pool。模型六：本文构建的 Ms RED 网络。

为评价各模型效果，选用的性能指标分别为：准确率 Accuracy (ACC)、召回率 Recall、精确率 Precision，计算公式如下：

$$ACC = \frac{TP + TN}{TP + TN + FN + FP} \quad (13)$$

$$Recall = \frac{TP}{TP + FN} \quad (14)$$

$$Precision = \frac{TP}{TP + FP} \quad (15)$$

式中， TP 表示预测为正，实际为正； FP 表示预测为正，实际为负； TN 表示预测为负，实际为负； FN 表示预测为负，实际为正。ACC、Recall、Precision 三种模型评价指标对比如表 2 所示。可以看出与模型一相比，模型四的 ACC 提高了 2.286%，证明了增加多尺度残差编码融合模块和多尺度残差解码融合模块可以自适应学习不同编码级别的特征权值，有效提高网络模型的准确度；与模型四相比，模

表 2 3 种模型评价指标对比

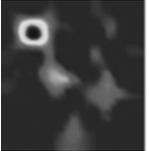
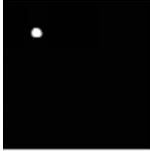
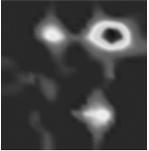
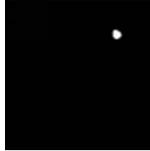
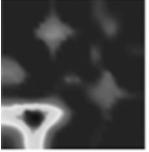
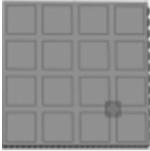
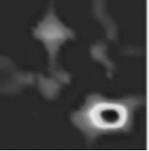
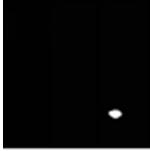
模型名称	ACC	Recall	Precision
模型一	0.883 5	0.854 3	0.853 9
模型二	0.886 5	0.852 8	0.861 5
模型三	0.894 5	0.858 3	0.861 4
模型四	0.898 1	0.854 4	0.877 9
模型五	0.899 8	0.895 2	0.883 4
模型六	0.913 7	0.897 5	0.887 8

型五的 ACC 提高了 0.189%，证明了 Soft-pool 可以更好地保留信息特征，提高网络准确率；与模型一相比，模型六的 ACC 提高了 3.418%，Recall 提高了 5.056%，Precision 提高了 3.971%，验证了添加模块的有效性和构造网络的有效性。

4.2 模型效果验证

为了验证模型成像的有效性，选取了如表 3 所示 4 种常见损伤进行实验分析，前文对比了 3 种传统成像算法，其中共轭梯度算法的成像效果较好因此本节选择共轭梯度算法成像图像和指标数据作为对照组，将共轭梯度算法成像效果与多尺度融合算法成像效果做对比。

表 3 不同损伤图像重建对比

类型	仿真模型	共轭梯度算法	多尺度融合算法
圆形损伤			
矩形损伤			
三角形损伤			
正方形损伤			

对比 Ms RED 算法和共轭梯度算法的成像质量可以看出，共轭梯度算法在反演图像的过程中仅能定位损伤的大致位置，缺乏对于损伤具体形状的表现能力，而 Ms RED 算法不仅能够较为精确地定位损伤位置，在对于损伤大小、形状的识别效果更好。

表 4 和表 5 所示对比了共轭梯度算法和 Ms RED 算法的图像相关系数和图像相关误差，可以看出，Ms RED 算法在 4 种损伤检测的相关系数更高，其 IME 指标数据也同样优于共轭梯度算法。

表 4 图像相关系数 CORR

缺陷类型	圆形损伤	矩形损伤	三角形损伤	正方形损伤
共轭梯度算法	0.785 5	0.740 1	0.679 4	0.745 6
Ms RED 算法	0.856 8	0.763 2	0.783 5	0.817 8

表 5 图像相对误差 IME

缺陷类型	圆形损伤	矩形损伤	三角形损伤	正方形损伤
共轭梯度算法	0.313 2	0.270 8	0.393 1	0.421 5
Ms RED 算法	0.242 8	0.212 4	0.298 3	0.313 5

从图 17 可以更加直观的看出 Ms RED 算法的优越之处，综合成像质量和指标数据共同验证了 Ms RED 算法在蜂窝复合材料损伤检测中的适用性，可以从图像中获得更有效的缺陷信息。

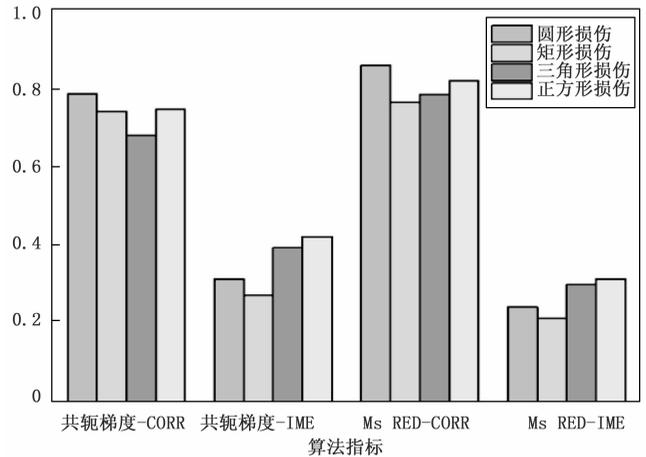


图 17 共轭梯度算法和 Ms RED 算法指标柱

5 结束语

本文提出基于平面 ECT 的航空蜂窝复合材料缺陷检测方法，构建了基于多尺度残差编码解码路径的深度神经网络 Ms RED 来进行 ECT 图像重建。详细介绍了基于平面 ECT 检测蜂窝材料的工作原理和图像重建的网络结构。结果表明：Ms RED 网络对于蜂窝复合材料缺陷的对真实分布的形状保真度更好。设置不同模块的消融实验对比，通过 ACC、Recall、Precision 三种模型评价指标验证了所添加模块的有效性，并对基于 Ms RED 的 ECT 图像重建算法进行验证，得到较高图像相关系数和较低图像相对误差^[20]，本网络获得的图像误差平均值为 0.266 7，图像相关系数平均值为 0.805 3，表明了 Ms RED 是一种有效的图像重建算法。

参考文献:

- [1] 许有昌. 碳纤维复合材料舱体超声波检测工艺研究 [D]. 南京: 南京理工大学, 2006.
- [2] 刘 雷. 弱磁技术在蜂窝复合材料检测中的应用研究 [D]. 南昌: 南昌航空大学, 2019.
- [3] 常俊杰, 李媛媛. 蜂窝结构复合材料的空气耦合 Lamb 波检测技术 [J]. 复合材料科学与工程, 2020 (2): 62-68.
- [4] 马 敏, 邓晨肖, 吴 轲. 平面阵列电容传感器优化 [J]. 传感器与微系统, 2020, 39 (3): 25-29.

(下转第 60 页)