

基于轻量级网络的飞机蜂窝结构积水缺陷检测

徐方^{1,2}, 刘文波^{1,2}, 汪荣华^{1,3}, 滕子煜^{1,2}

(1. 南京航空航天大学自动化学院, 南京 211106;

2. 高速载运设施的无损检测监控技术工业和信息化部重点实验室, 南京 211106;

3. 国营芜湖机械厂, 安徽 芜湖 241000)

摘要: 复合材料蜂窝结构在飞机服役过程中产生的积水缺陷在日常维护和检修过程中依赖人工、检测效率低、自动化程度低, 若未能及时发现将严重威胁飞行安全; 针对该问题, 结合实际检修场景中使用的移动或嵌入式设备算力有限的情况, 设计了一种融合通道注意力和倒残差算法的模块 SE-IR, 进一步搭建了基于 SE-IR 模块的轻量级网络 SE-IR LCNN, 尽可能地在保证网络检测准确率的同时减小网络的参数量; 为了验证所提轻量级网络的有效性, 使用数字 X 射线摄影设备获取蜂窝结构及其积水缺陷数字化图像并制成数据集; 在该数据集上的实验结果表明, 所提轻量级网络的分类准确率为 99.20%, 可有效筛选出飞机蜂窝结构的积水缺陷; 相较于经典网络 ResNet-50 和 VGG-16, 所提网络的准确率分别提升了 9.6% 和 3.66%、参数量仅为 ResNet-50 参数量的 1/10、VGG-16 参数量的 1/50。

关键词: 航空复合材料; 蜂窝结构积水; 无损缺陷检测; 倒残差结构; 通道注意力机制

Water Ingress Detection of Aircraft Honeycomb Structure Based on Lightweight Network

XU Fang^{1,2}, LIU Wenbo^{1,2}, WANG Ronghua^{1,3}, TENG Ziyu^{1,2}

(1. College of Automation Engineering, Nanjing University of Aeronautics & Astronautics, Nanjing 211106, China;

2. Non-Destructive Testing and Monitoring Technology for High-Speed Transport Facilities Key Laboratory of

Ministry of Industry and Information Technology, Nanjing 211106, China;

3. Wuhu State-Owned Factory of Machining, Wuhu 241000, China)

Abstract: The water ingress defects of composite honeycomb structure produced in the service process of aircraft will seriously threaten flight safety. The detection of water ingress defects rely on manual work, low detection efficiency and low degree of automation in the daily maintenance and overhaul process. Aiming at this problem, considering the limited computing power of mobile or embedded devices used in actual maintenance scenarios, a module SE-IR that integrates squeeze and excitation block and inverted residual algorithm is designed, and a lightweight network SE-IR LCNN based on SE-IR module is further built. As much as possible to ensure the accuracy of network detection while reducing the number of network parameters. In order to verify the effectiveness of the proposed lightweight network, digital X-ray photography equipment is used to obtain digital images of honeycomb structures and their water defects and make data sets. The experimental results on this dataset show that the classification accuracy of the proposed lightweight network is 99.20%, which can effectively screen out the water accumulation defects of aircraft honeycomb structure. Compared with the classical network ResNet-50 and VGG-16, the accuracy of the proposed network is increased by 9.6% and 3.66% respectively, and the number of parameters is only 1/10 of the number of parameters of ResNet-50 and 1/50 of the number of parameters of VGG-16.

Keywords: aviation composites; honeycomb structure water ingress; non-destructive defect detection; squeeze and excitation block; inverted residual structure

0 引言

蜂窝夹层结构是航空器结构中最理想、结构效率最高的形式之一。蜂窝夹层结构复合材料由蜂窝芯、面板和胶粘剂组成, 具有质量轻、比强度和比刚度、导热系数低、

抗失稳能力强、耐疲劳老化、吸音隔音等优点, 已广泛应用于军用和民用飞机机身、机翼、尾翼、方向舵、雷达罩、地板等结构^[1-3]。如 F-35 飞机的襟、副翼、平尾前缘、垂尾边缘、方向舵等均采用了蜂窝夹层结构^[2], 空中客机公

收稿日期: 2023-02-17; 修回日期: 2023-03-08。

基金项目: 国家重点研发计划(2018YFB2003304, 2017YFF0107304, 2017YFF0209700, 2016YFB1100205, 2016YFF0103702); 国家自然科学基金(61871218, 61527803); 中央高校基本科研业务费(NJ2019007, NJ2020014)。

作者简介: 徐方(1999-), 女, 河南南阳人, 硕士研究生, 主要从事无损检测、深度学习方向的研究。

刘文波(1968-), 女, 辽宁海城人, 博士, 教授, 主要从事信号处理、计算机测控技术方向的研究。

引用格式: 徐方, 刘文波, 汪荣华, 等. 基于轻量级网络的飞机蜂窝结构积水缺陷检测[J]. 计算机测量与控制, 2023, 31(8): 64-69, 97.

A380 飞机上蜂窝夹层结构复合材料的用量达 4 000 m², 中国商飞公司 C919 大型客机舱门、客货舱、地板等结构使用了蜂窝夹层结构材料。

随着飞机服役年限的增加, 蜂窝结构在工作载荷作用下密封性下降, 工作环境中的雨水、漏水、冷凝水等渗漏其中, 造成积水缺陷。蜂窝芯格积水不仅破坏飞机载荷平衡, 还会进一步引起蜂窝结构脱胶、内部腐蚀、结冰胀裂、结构强度降低等问题, 危及飞行安全^[4]。因此, 在飞机日常检修和定期大修期间, 检测蜂窝结构积水是一项必要且十分重要的工作。

针对飞机蜂窝结构积水缺陷无损检测, 国内外开展了一系列研究^[4-7], 按照数据采集方法的不同, 蜂窝夹层积水缺陷无损检测方法大致可分为: 超声法、微波平板波导法、介电常数调制法、红外法、微波法、全息雷达法、激光错位散斑法、X 射线成像法^[8-13]。超声检测蜂窝积水信噪比低; 红外热成像检测技术容易受加热不均匀、蜂窝夹层结构表面反射率及表面形状的影响, 检测能力受到一定限制; 由于探测波长的限制, 平行平板波导法和微波全息雷达成像法只适用于特定材质的蜂窝夹层结构复合材料; 介电常数调制法需要对仪器输出的一维电压信号进行分析来推测待测样件积水情况, 当蜂窝芯格内的积水深度低于 2 mm 时, 介电常数调制法不能检测出该缺陷。

X 射线成像技术具有检测效率高、非接触、无需耦合、显示结果直观、不受限于被测样件材料等优点, 数字 X 射线成像 (DR, digital radiography) 相较于传统胶片成像具有分辨率高、动态范围大、信噪比高、X 射线曝光剂量低检测结果直观等优点^[4,14], 适合用于检测蜂窝结构复合材料内部的积水缺陷。对于 DR 设备采集的高质量图像, 目前的研究者仍然依靠目视 X 射线图像的方法确定蜂窝结构内部是否存在积水缺陷^[15-17]。依靠人工目视的方法效率低、耗时长、自动化程度低。

对于蜂窝结构 DR 图像, 基于图像处理和统计学习的传统缺陷检测方法需要依靠设计者的先验知识, 根据特定的数据类型和领域特性设计选取图像的形状、纹理、颜色等底层视觉特征或尺度不变特征变换^[18]、局部二值模式^[19]、方向梯度直方图^[20]等局部不变特征, 人工设计选取特征十分困难且耗费时间。近年来, 随着深度学习在计算机视觉应用领域不断取得成功, 人们开始寻求将深度学习用于工业缺陷检测, 并逐渐发展为工业缺陷检测领域的主流方法。相较于基于图像处理与统计学习的传统方法, 卷积神经网络 (CNN, convolutional neural network) 无需手工设计特征, 而是依靠强大的特征提取能力和对高维特征的表征能力自动学习人类难以设计的特征, 更加适用于处理复杂的工业图像数据^[21-22]。

现有的卷积神经网络具有参数量较大、难以部署在移动或嵌入式设备的局限性。本文提出一种用于筛选检测蜂窝结构中积水缺陷的轻量型卷积神经网络, 可用于飞机蜂窝结构件无损检测的工业检修场景, 提升蜂窝积水检测的

准确率、效率和自动化程度。也可在漏检后果严重的检修场景下作为一项辅助或检验技术。

1 轻量级网络 SE-IR LCNN 设计基础

1.1 可分离卷积

卷积层是卷积神经网络的基本运算单元, 从输入数据中提取抽象的特征信息。卷积运算是构建卷积层的基础。在数学上, 卷积运算是两个实变函数乘积的一种特殊积分形式, 一维连续函数 $x(t)$ 、 $w(t)$ 的卷积 $s(t)$ 定义为:

$$s(t) = (x * w)(t) = \int x(a)w(t-a)da \quad (1)$$

常规卷积即标准卷积 (Std Conv, standard convolutional)。如图 1 (a) 所示, 对输入的三通道图像, 预设输出通道数为 4 即输出特征层包含 4 个特征图时, 常规卷积层中包含 4 个卷积核, 每块由 3 个大小为 3×3 的卷积核堆叠构成。常规卷积层的参数量 N_{std} 为:

$$N_{std} = 4 \times 3 \times 3 \times 3 = 108 \quad (2)$$

可分离卷积由 Google 于 2017 年提出^[23], 核心思想是将一个完整的卷积运算分解为两步进行, 分别为深度卷积 (DW Conv, depthwise convolution) 和逐点卷积 (PW Conv, pointwise convolution)。

DW Conv 对输入特征层的每个通道单独进行卷积操作, 输出特征层通道数与输入特征层通道数相同。DW Conv 卷积层中卷积核的数量与输入特征层相同, 如图 1 (b) 所示, DW Conv 卷积层的参数量 N_{dw} 为:

$$N_{dw} = 3 \times 3 \times 3 = 27 \quad (3)$$

DW Conv 单独对输入特征层的每个通道进行处理, 未能有效利用不同特征图在相同空间位置上的信息, 因此需要进一步使用 PW Conv 将输出的特征图进行组合生成新的特征图。

PW Conv 卷积层中的每个卷积核由 n 个 1×1 卷积核堆叠构成, n 为 PW Conv 输入特征层的通道数。如图 (b) 所示, PW Conv 将 DW Conv 输出的特征图在深度方向上进行加权组合, 生成新的特征图。PW Conv 卷积层的参数量 N_{pw} 为:

$$N_{pw} = 1 \times 1 \times 3 \times 4 = 12 \quad (4)$$

可分离卷积的总参数量 $N_{separable}$ 为:

$$N_{separable} = N_{dw} + N_{pw} = 39 \quad (5)$$

当输入图像相同, 输出特征层中都含有 4 张特征图时, 可分离卷积的参数量约为常规卷积的 1/3, 当限制卷积神经网络的参数量时, 使用可分离卷积可以将网络层数做的更深, 从而提升卷积神经网络的性能。为了达到神经网络的轻量化效果, 便于部署在工业缺陷检测过程中使用的移动和嵌入式设备等算力较低的设备上, 本文使用可分离卷积搭建网路。

1.2 倒残差结构

残差结构由微软实验室于 2015 年发表的 Resnet 论文中提出^[24], 倒残差结构由谷歌团队于 2018 年发表的 MobileNetV2 论文中提出^[25]。倒残差结构与残差结构的不同之处

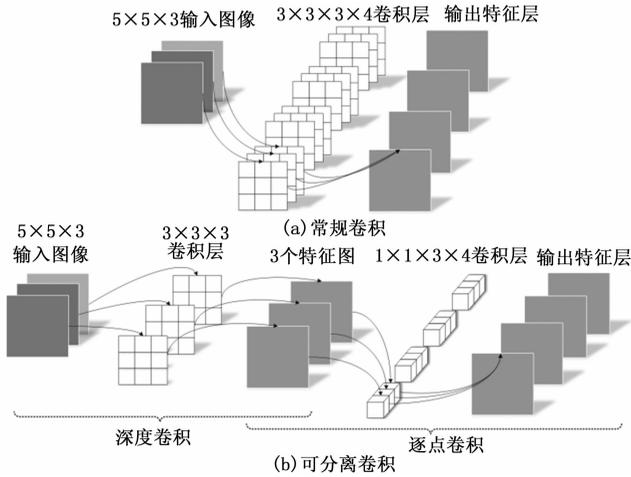


图 1 常规卷积与可分离卷积组成示意图

主要体现在 3 个方面：一是特征维度变化过程不同，二是采用的特征提取卷积形式不同，三是使用的激活函数不同。

如图 2 (a) 所示，残差结构先通过先使用 1×1 的 PW Conv 实现降维，再使用 3×3 Std Conv 提取特征，最后使用 1×1 的 PW Conv 升维，使输出特征通道数与输入特征通道数保持一致。如图 2 (b) 所示，残差结构运算过程中，特征通道数即特征维度的变化过程呈现出一个两头大、中间小的沙漏型结构。图 2 (c) 中，倒残差结构先使用 1×1 的 PW Conv 对特征进行升维，再使用 3×3 的 DW Conv 提取特征，最后使用 1×1 的 PW Conv 降维。使输出特征通道数与输入特征通道数保持一致。如图 2 (d) 所示，倒残差结构运算过程中，通道数即特征维度的变化过程呈现出一个两头小、中间大的梭型结构。

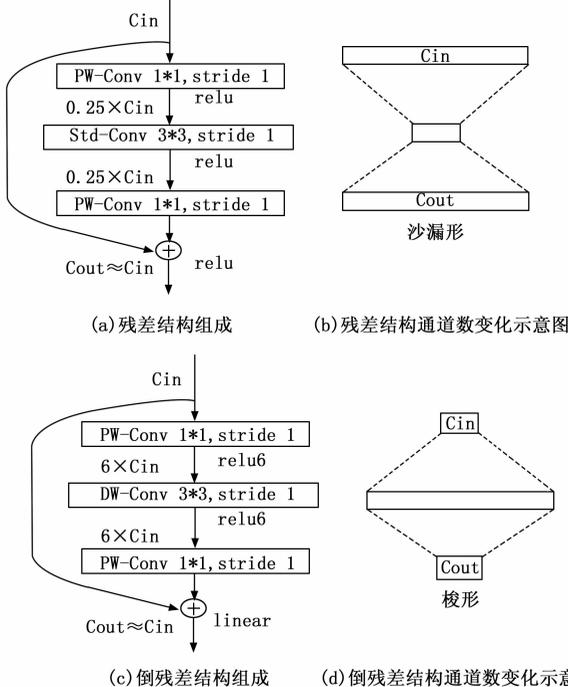


图 2 残差结构和倒残差结构示意图

DW Conv 中卷积块的数量取决于输入特征的通道数，无法进行改变。倒残差结构中使用 PW Conv 升维扩充了通道数，使 DW Conv 能够在高维空间上提取更多的信息，达到更好的训练效果。

残差结构中统一采用 ReLu 激活函数，倒残差结构中，升维和特征提取后采用 ReLu6 激活函数，降维后采用线性激活函数。ReLu 的输出范围是零到正无穷，当不对其输出范围作出限制时，低精度 16 位浮点数无法精确描述其数值，带来精度损失。ReLu6 激活函数的输出上界为 6，可以保证移动端设备在 float16 低精度情况下，也能够保有有很好的数值分辨率。

1.3 通道注意力机制

通道注意力网络 (SENet, squeeze and excitation network) 由 Momenta 公司所属团队于 2017 年提出^[26]，并斩获当年 ImageNet 比赛中图像分类任务的冠军。SENet 的核心为通道注意力模块 (SE, squeeze and excitation block)。SE 不是一个完整的卷积神经网络结构，而是一个子模块，可以嵌入到分类或检测模型中。

SE 的核心思想是通过网络学习并调整每个特征通道的重要程度，提高有用的特征图的权重、降低无效的特征图的权重从而使模型达到更好的训练效果。SE 由压缩、注意力和重标定三部分组成，SE 原理如图 3 所示。压缩阶段，使用全局均值池化由大小为 $C \times H \times W$ 的特征层得到大小为 $1 \times 1 \times C$ 的具有全局感受野的特征图；注意力阶段，首先生成每个特征通道的权重，然后使用参数 W 显式地建模特征通道间的相关性；重标定阶段，将注意力阶段输出的各通道权重，通过乘法逐通道加权到各特征通道上，完成对特征图的重标定。

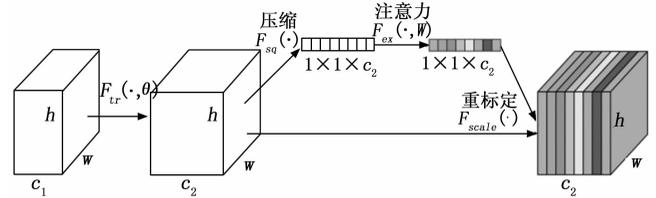


图 3 注意力机制原理示意图

图中， $F_{tr}(\cdot, \theta)$ 为标准卷积；压缩阶段由全局均值池化 (GAP, global average pooling) 算法实现 GAP 对每个通道的二维图像做平均，将 $H \times W \times C_2$ 的输入转换为 $1 \times 1 \times C_2$ 的输出，获取 C_2 个特征图的全局信息。Squeeze 过程的数学表达式为：

$$z_c = F_{sq}(u_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j) \quad (6)$$

式中， u_c 表示 U 中的第 c 个特征图。

注意力阶段依次通过全连接层 (FC, fully connected neural network) FC1、ReLu 激活函数、全连接层 FC2、Sigmoid 激活函数获取特征图权重。注意力阶段的数学表达式为：

$$s_c = F_{ex}(z, W) = \sigma(g(z, W)) = \sigma(W_2 \delta(W_1 z)) \quad (7)$$

式中， s_c 为 U 中 C_2 个特征图的权重， s 的维度为 $1 \times 1 \times C_2$ 。

W_1, W_2 为两个全连接层。 W_1, W_2 的维度为:

$$D_{W_1} = C_2 / r * C_2 \quad (8)$$

$$D_{W_2} = C_2 * C_2 / r \quad (9)$$

式中, r 是为了减少通道数从而降低参数数量的缩放参数, 取 $r = 16$ 。

对于 U 中的第 c 个特征图, 重标定过程将二维特征图 u_c 与其权重 s_c 进行融合, 即对 u_c 中的每个值乘以 s_c , 从而对特征图进行重标定。重标定过程的数学表达式为:

$$\tilde{X}_c = F_{scale}(u_c, s_c) = s_c \cdot u_c \quad (10)$$

式中, \tilde{X}_c 为 SE 生成的 U 中的第 c 个特征图对应的新的特征图。

2 融合注意力机制的倒残差模块设计

2.1 融合注意力机制的倒残差模块式设计

为了满足飞机蜂窝结构积水缺陷工业检修环境中对检测效率的要求, 适应检测场景中的较低算力的移动或嵌入式设备, 尽可能地在保证检测精度的同时减小卷积神经网络的参数量。本文设计了一种融合通道注意力和倒残差算法的模块 SE-IR (squeeze and excitation-inverted residual module)。SE-IR 的组成结构如图 4 所示。

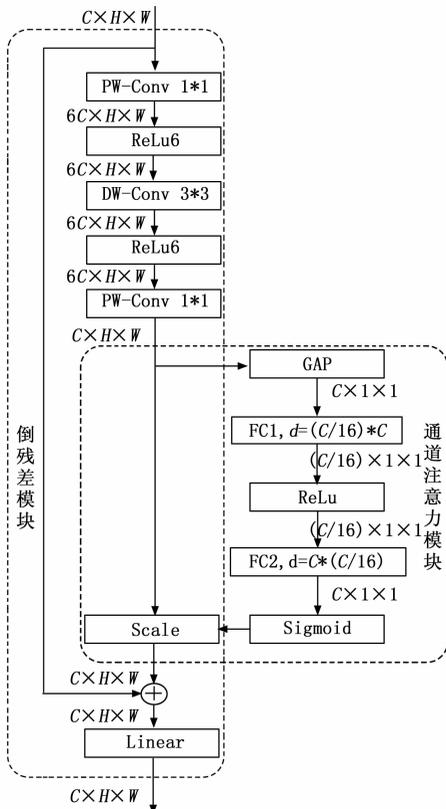


图 4 SE-IR 模块组成结构示意图

使用的激活函数的数学表达式如表 1 所示。

表 1 SE-IR 中使用的激活函数

激活函数	表达式
Sigmoid	$f(x) = \frac{1}{1 + e^{-x}}$
ReLu	$f(x) = \max(0, x)$
ReLu6	$f(x) = \min(\max(x, 0), 6)$

2.2 基于 SE-IR 的轻量级网络设计

设计了一种基于 SE-IR 模块的轻量级卷积神经网络 SE-IR LCNN (lightweight convolutional neural network base on SE-IR)。

SE-IR LCNN 的组成如图 5 所示, 网络结构中共含有 5 个卷积层, 1 个池化层, 1 个输出层。输入图像是大小为 224×224 的三通道图像, 首先经过 3×3 标准卷积层 Conv1, 步长为 2, 对输入图像进行降采样; Conv2 由 2 个 SE-IR 模块连接组成, 步长为 1; Conv3、Conv4、Conv5 均由 3 个 SE-IR 模块连接组成, 步长为 2。输入图像经过卷积层提取特征后输出特征图尺寸为 7×7 , 通道数为 256, 通过池化层的自适应均值池化投影到归一化指数函数 softmax 层, 将分类结果以概率形式输出, 实现对含有积水缺陷的蜂窝结构图像的筛选。

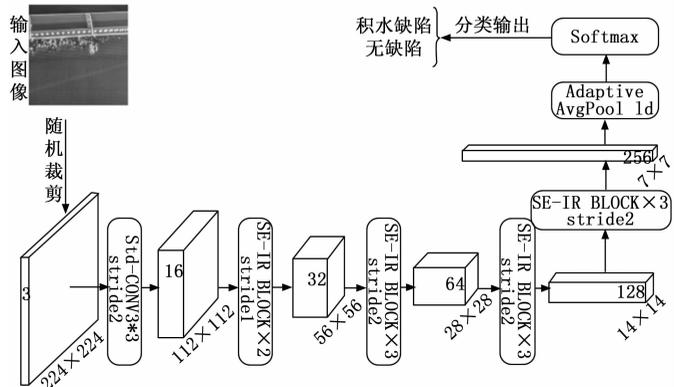


图 5 SE-IR LCNN 组成示意图

3 实验与分析

3.1 实验数据获取

由于没有飞机蜂窝结构 X 射线图像公开数据集, 本文以主要材料为蜂窝结构的某型飞机方向舵作为检测对象开展实验研究。该方向舵中蜂窝结构复合材料的上下蒙皮材质为碳纤维, 蜂窝芯材为正六边形芳纶纸蜂窝, 外形尺寸约为 $2\ 900\ \text{mm} \times 1\ 000\ \text{mm}$ 。

X 射线是电磁辐射的一种形式, 在电磁波谱中处于高频位置。大多数 X 射线的波长范围在 $0.01 \sim 10\ \text{nm}$ 之间, 对应的频率范围 $30\ \text{PHz} \sim 30\ \text{EHz}$ 之间。X 射线的能量通常在 $100\ \text{eV} \sim 100\ \text{keV}$ 之间, 光子能量超过 $10\ \text{keV}$ 的射线称为硬 X 射线, 否则称为软 X 射线。X 射线在真空中以光速传播, 不受电场、磁场的影响; X 射线具有很强的穿透性, 在媒介中沿直线传播; X 射线具有感光性和荧光性, 可使照相底片感光、使某些物质发出荧光; X 射线在媒介表面可发生反射、折射, 对于常见媒介, 折射率接近于 1。X 射线无损检测技术是 X 射线直线性、穿透性、感光性或荧光性的应用。

X 射线无损检测的物理基础是 X 射线在被照射物体中由于散射和吸收产生的能量衰减变化。物理实验表明, 当

一束射线在均匀介质中传播时，在很小的厚度范围内强度的衰减量与入射射线强度和穿透介质的厚度成正比^[27]，即：

$$I = I_0 e^{-\mu H} \quad (11)$$

式中， I_0 为入射线强度； I 为透射射线强度； μ 为射线的线衰减系数 (cm^{-1})； H 为射线穿透介质的厚度。

如图 6 所示，当被检测样件内部存在一个很小的缺陷区时，检测样件在射线透射方向的厚度差与物质对比度之间的关系如式 (12) 所示：

$$\frac{I + I'}{I} = \frac{(\mu - \mu')\Delta H}{1 + n} \quad (12)$$

式中， I 为均匀区域透射线强度， I' 为缺陷区域透射线强度； μ 为检测构件的线衰减系数， μ' 为缺陷区域线衰减系数； H 为检测构件厚度， ΔH 为缺陷区域厚度，且通常有 $\Delta H \ll H$ ； n 为均匀区域和缺陷区域对射线的散射比。

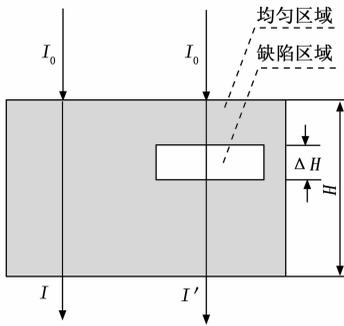


图 6 X 射线缺陷检测原理示意图

X 射线对缺陷的检测能力与缺陷在缺陷透照方向上的尺寸、缺陷区域与均匀区域线衰减系数的差异和散射线的控制有关。当飞机蜂窝结构复合材料存在积水缺陷时，X 射线透射后会产生一定的物体对比度，并在探测器上产生一定灰度对比度，从而达到检测积水缺陷的目的。基于上述原理，只要蜂窝结构中积水缺陷造成的物质对比度可以达到探测器和图像显示器可分辨的灰度极差，即可在 X 射线图像中显示出该缺陷。

DR 是一种直接数字射线检测方法，具有图像质量好、图像分辨率高、检测效率高、检测结果便于存储传输等优点。如图 7 所示，本文使用的 DR 系统主要由射线机、探测器、显示器、通讯线缆组成。



图 7 DR 检测系统示意图

本文开展实验使用的 DR 检测系统中，射线机使用美国 GE 公司的 ERESKO 160MF4-R 便携式软射线机，其射线管材质为金属陶瓷、阳极材料为钨 (W)。探测器使用以色列 NOVO 公司的 NOVO-22WN 便携式非晶硅平板面阵探测

器，其闪烁体材质为硫氧化钆 (GOS)。从检测对象中透射出的 X 射线通过非晶硅闪烁体时，闪烁体上的硫氧化钆涂层在 X 射线的作用下产生荧光，荧光被光电二极管收集后产生电信号，最终通过薄膜晶体管阵列转换为数字图像输出。DR 检测系统的主要部件参数如表 2 所示。

表 2 DR 检测系统部件主要参数

部件	参数名称	参数
ERESCO 160MF4-R 便携软射线机	X 射线管材质	金属陶瓷
	阳极材料	钨 (W)
	射线管电流	0.5~10 mA
	射线管头直径	160 mm
	焦点尺寸	1.0 mm
NOVO-22WN 便携非晶硅 平板面阵探测器	靶角	20°
	闪烁体材质	硫氧化钆 (GOS)
	外形尺寸	462 mm×385 mm×15.6 mm
	成像区尺寸	427 mm×356 mm
	像素间距	148 μm
	分辨率	3.38 lp/mm
	动态范围	16 bit

参考无损检测 X 射线数字成像检测方法相关标准^[28]，实验过程中 DR 检测系统的主要参数为电压 38 kV、电流 5 mA、积分时间 2.0 s、焦距 1 400 mm、双丝 $IQI \geq D6$ 。

采集的飞机方向舵 DR 图像如图 8 所示，为 RGB 三通道彩色图像，分辨率为 2 878×2 352，水平和垂直分辨率均为 172 dpi，位深度为 24。积水缺陷在 DR 图像上呈现为不规则的明亮区域。经过简单预处理后将获取的 DR 图像随机剪裁为 224×224 大小，实验数据集中共 3 000 张图像。

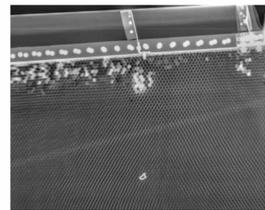


图 8 方向舵蜂窝结构 DR 图像

3.2 实验环境配置

本文基于 PyTorch 1.10.2 深度学习框架开展实验，程序运行环境为 Windows 10 操作系统，编译器为 Python 3.6.13，CUDA 版本为 CUDA 11.2，cuDNN 版本为 cuDNN 8.1.1。

硬件平台的处理器为内存 16 GB 的 AMD Ryzen 7 5800U，显卡为内存 4 GB 的 NVIDIA GeForce RTX3050。

3.3 评价指标

对卷积神经网络分类任务模型性能的评价需要借助的混淆矩阵，真正例 (TP, true positive) 表示网络模型预测为正且真实情况为正，假正例 (FP, false positive) 表示网络模型预测为正真实情况为反，假反例 (FN, false negative) 表示网络模型预测为反且真实情况为正，真反例

(TN, true negative) 表示网络模型预测为反且真实情况为反。准确率是指网络模型预测结果中正确的比例, 准确率越高, 表示模型的效果越好。借助混淆矩阵, 模型准确率的计算公式为:

$$accuracy = \frac{TP + TN}{TP + FP + TN + FN} = \frac{\text{预测正确的样本数}}{\text{总样本数}} \quad (13)$$

参数量是网络空间复杂度的衡量标准, 参数量越小, 网络运行过程中占用内存空间越小, 网络越轻量化。

3.4 实验结果与分析

以 3: 1: 1 的比例划分训练集、验证集和测试集, 初始学习率设置为 0.001, 批大小设置为 4, 训练 150 个 epoch。网络训练过程中的训练损失和验证准确率的变线如图 9 所示。

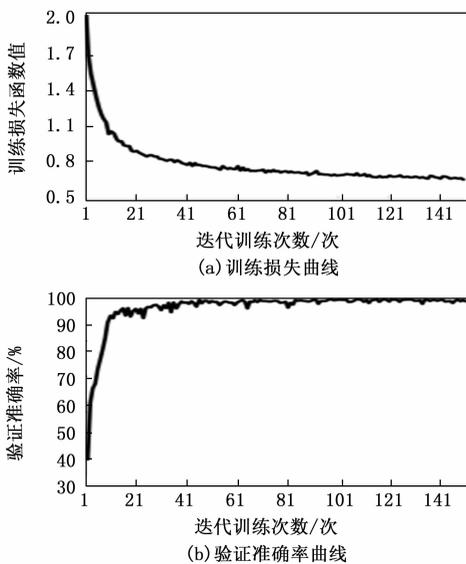


图 9 模型性能曲线

由训练损失曲线可知, 在经过 20 次迭代后, 训练损失开始收敛、趋于稳定, 经过 100 次迭代后, 训练损失达到稳定, 说明所提网络模型运行正常且达到非常好的拟合效果。由验证准确率曲线可知, 在 20 次迭代以内, 网络即可达到较高的验证准确率, 体现了所提网络模型的有效性。

为了定量比较本文网络与研究领域内常见网络, 使用准确率和参数量来衡量网络的综合性能。为了保证实验结果的有效性, 在所有网络训练时设置相同的参数, 使用同一硬件平台在相同软件环境下开展实验, 数据集均采用本文采集并制作的蜂窝结构 DR 数据集。实验结果如表 3 所示。

表 3 不同网络性能比较

网络名称	参数量	准确率/%
ResNet-50	2.7×10^7	89.6
ResNet-DTL	1.12×10^7	99.46
VGG16	6.51×10^7	95.54
MobileNet	3.22×10^6	92.46
ours	1.17×10^6	99.20

从表 3 可以看出, ResNet-DTL 网络达到了最高的准确率 99.46%, 但参数量是本文网络的 9.57 倍。相较于研究领域内代表性的网络 ResNet-50, 本文网络的准确率提高了 9.6%, 参数量仅为 ResNet-50 的 4.33%; 相较于 VGG16 网络, 本文网络的准确率提高了 3.66%, 参数量则减小了 55.64 倍。同样使用可分离卷积的 MobileNet 网络参数量与本文网络最为接近, 参数量为本文算法的 2.75 倍, 但准确率相较于本文网络降低了 6.74%。综上表明, 本文算法在飞机蜂窝结构积水缺陷检测任务中表现较佳, 在保证高准确率的同时, 大大地降低了参数量, 减轻了网络运行过程中硬件环境的负担, 便于嵌入在实际检修场景中算力有限的设备中。

4 结束语

本文提出了一种融合倒残差结构和通道注意力机制的轻量化卷积神经网络, 即 SE-IR LCNN, 对飞机蜂窝结构中的积水缺陷进行检测。该网络能够达到较高的准确率、较为符合飞机检修低漏检率的要求, 且能在不影响检测准确率的同时显著减少网络参数量, 更适合移植到飞机检修场景中经常使用的移动或嵌入式设备等算力有限的硬件平台中。本文提出的网络可以用于提高飞机蜂窝积水无损检测过程中的检测效率和自动化程度, 也可在仍然以人工为主的检测过程中作为一项辅助技术。

参考文献:

[1] CASTANIE B, BOUVET C, GINOT M. Review of composite sandwich structure in aeronautic applications [J]. Composites Part C: Open Access, 2020, 1: 100004.

[2] 陈 静, 邱启艳. 蜂窝夹层结构在飞机上的应用及发展 [J]. 新材料产业, 2018 (7): 63-67.

[3] 马志阳, 高丽敏, 徐吉峰. 复合材料在大飞机主承力结构上的应用与发展趋势 [J]. 航空制造技术, 2021, 64 (11): 24-30.

[4] 曲亚林, 宁 宁, 詹绍正. 蜂窝夹芯结构的无损检测技术 [J]. 航空制造技术, 2011 (20): 78-81.

[5] GUPTA R, MITCHELL D, BLANCHE J, et al. A review of sensing technologies for non-destructive evaluation of structural composite materials [J]. Journal of Composites Science, 2021, 5 (12): 319.

[6] 刘松平, 刘菲菲. 先进复合材料无损检测技术 [M]. 北京: 航空工业出版社, 2017.

[7] 刘松平, 刘菲菲, 李乐刚, 等. 航空复合材料无损检测与评估技术研究进展回顾 [J]. 航空制造技术, 2019, 62 (14): 14-27.

[8] 涂 俊, 危 荃, 王 飞. 用于航天蜂窝结构的激光与红外无损检测技术 [J]. 激光与红外, 2014 (11): 1220-1223.

[9] BRINKER K, DVORSKY M, AI QASEER M T, et al. Review of advances in microwave and millimetre-wave NDT&E: Principles and applications [J]. Philosophical Transactions of the Royal Society A, 2020, 378 (2182).

(下转第 97 页)