

基于一维 CNN 的碳纤维复合材料缺陷类型判别

詹湘琳**, 赵婉婷*

中国民航大学电子信息与自动化学院, 天津 300300

摘要 针对碳纤维复合材料(CFRP)的缺陷类型自动判别,提出一种超声一维卷积神经网络(U-1DCNN),结合贝叶斯优化方法进行超参数优选,通过自动提取超声 A-Scan 信号特征,实现分层、气孔、无缺陷三种类型自动区分。首先采集超声 A-Scan 信号构建数据集,然后利用多卷积块同时进行特征提取,以增强提取特征的多样性,并将一维残差单元堆叠连接,在进一步提取特征的同时简化网络的训练,利用贝叶斯优化算法优选网络的学习率和随机梯度下降的动量参数,最终实现了 A-Scan 信号与缺陷类型的非线性映射。实验结果表明,U-1DCNN 可通过自动提取特征实现 CFRP 的缺陷类型识别,准确率为 99.50%,并且较二维卷积神经网络方法识别速度更快,可辅助缺陷检测结果判断。

关键词 图像处理; 缺陷类型识别; 卷积神经网络; 超声信号; 碳纤维复合材料(CFRP)

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP57.101013

Classification of Carbon Fiber Reinforced Polymer Defects Based on One-Dimensional CNN

Zhan Xianglin**, Zhao Wanting*

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

Abstract Aiming at classification of carbon fiber reinforced polymer (CFRP) defect types, an ultrasonic one-dimensional convolutional neural network (U-1DCNN) is proposed and the Bayesian optimization algorithm is used to optimize hyperparameters. By automatically extracting the features of ultrasonic A-Scan signals, three defect types, i. e., delamination, gas cavity, and non-defect, are automatically distinguished. First, a dataset is constructed by collecting ultrasonic A-Scan signals. Then, multi-convolutional blocks are used to simultaneously extract as well as enhance the diversity of extracted features. Subsequently, one-dimensional residual units are stacked and connected, simplifying the training of the network while further extracting the features. The learning rate and momentum parameter of stochastic gradient descent of the network are optimized by Bayesian optimization algorithm. Finally, nonlinear mapping of the A-Scan signals and defects is realized. Experiment results show that U-1DCNN can recognize CFRP defects by automatically extracting features, with the accuracy reaching 99.50%. The recognition speed of U-1DCNN is faster than the two-dimensional CNN method, which is advantageous for defect detection.

Key words image processing; identification of defect types; convolutional neural network; ultrasonic signals; carbon fiber reinforced polymer(CFRP)

OCIS codes 100.4996; 120.4290; 110.7170; 150.1135

1 引言

碳纤维复合材料(CFRP)具有高比强度、比刚

度等特点,在航空、军事等领域应用越来越广泛。相对于金属,复合材料的缺陷损伤形式更多,并且可能在表面不可见^[1],不同的缺陷类型会对复合材料构

收稿日期: 2019-09-16; 修回日期: 2019-10-08; 录用日期: 2019-10-18

基金项目: 国家自然科学基金(61102097)、天津市科技支撑计划项目(11ZCGHHZ00700)、天津市高等学校创新团队培养计划资助(TD13-5071)

* E-mail: zhaowtw@163.com; ** E-mail: xlzhan@cauc.edu.cn

件造成不同的影响,对应的处理方案也不同,因此有必要对缺陷类型进行识别^[2]。目前,超声无损检测方法在CFRP的缺陷检测上效果显著,但检测结果的判读一般需要由专业的检测人员进行,这使得缺陷检测工作量大、效率低,并且影响后续构件维修与性能评估。

目前,已有不少学者对CFRP超声检测中缺陷类型识别问题进行研究,可总结为首先利用数字信号处理方法对信号进行分析,提取特征;然后借助分类模型(例如神经网络、支持向量机等)实现缺陷分类,其中关键问题之一是特征的提取与选择。超声回波信号特征主要有时域特征、频域特征等,这些特征的选取影响着缺陷分类的效果。特征提取的方法包括小波包变换^[3](WPT)、离散小波变换(DWT)、聚类DWT^[4]、梅尔频率倒谱系数法^[5]、经验模态分解^[6]等,特征提取完成后,建立并训练分类模型,实现缺陷类型区分。除了上述方法外,近几年卷积神经网络(CNN)方法在目标检测^[7]、医学^[8]、交通^[9]等方面应用广泛,在缺陷分类上也逐渐开始应用^[10]。已有研究者利用CNN对不锈钢板的超声检测图像进行自动分类^[11]。在对超声信号分类时,可将小波包分解系数作为CNN的输入^[12],但这种方法仍需借助人工对信号进行处理后再提取特征,并且需要考虑不同的小波基函数对识别结果的影响。超声回波信号与轴承的振动信号类似,均是非平稳的一维信号,在轴承故障诊断上,有研究人员利用一维CNN对原始振动信号进行学习^[13],并取得了较好的效果。文献[14]使用一维CNN分类超声回波信号,但在验证数据集上准确率仅为66.5%。

目前进行复合材料缺陷分类时较多依赖人工进行特征提取,这会导致缺陷识别过程复杂且耗时,且一旦选取的特征不合适,分类效果会受到很大的影

响。因此,本文针对如何利用超声信号进行缺陷自动分类问题,提出一种超声一维CNN(U-1DCNN)模型来实现CFRP的缺陷类型自动区分。该模型采用多卷积块并行结构结合一维残差单元堆叠,实现超声信号中携带的缺陷类型特征自动提取,并且在特征提取更加多样化的同时使网络更容易训练;针对分类模型训练时调参耗时问题,采用贝叶斯优化方法自动优选U-1DCNN模型的超参数(学习率和随机梯度下降动量参数)。U-1DCNN可以从原始A-Scan信号中提取特征,减少人为进行特征提取造成的有效特征丢失或特征提取不准确等问题,实现CFRP缺陷类型的自动区分。

2 缺陷自动分类系统

随着CFRP材料的广泛应用和超声无损检测技术的发展,对材料的缺陷检测不仅仅局限于检测出有无缺陷,而是逐渐向着缺陷的定量评估、检测过程自动化和数据管理智能化的方向发展^[15],对缺陷类型实现自动区分,可以更好地对CFRP构件进行维修处理与后续性能评估。图1所示为实现CFRP缺陷类型自动识别的整体流程,分为数据采集与整理、分类模型构建与训练、模型测试与结果输出三部分。数据采集部分利用超声检测仪器OmniScan_MX2进行缺陷检测,将采集到的A-Scan信号输入计算机,读取并添加标签,构建A-Scan信号数据集。数据集整理结束后,构建分类模型,分类模型中包含特征提取和分类器,通过训练分类模型将提取的特征与相应的数据标签形成对应关系,其中特征提取可人工进行,即图1中的(1)与(2)过程,也可利用CNN等方法自动提取特征,即图1中的(3)过程。分类模型训练完成后,使用测试集中的A-Scan信号进行测试,验证分类模型的分类效果。

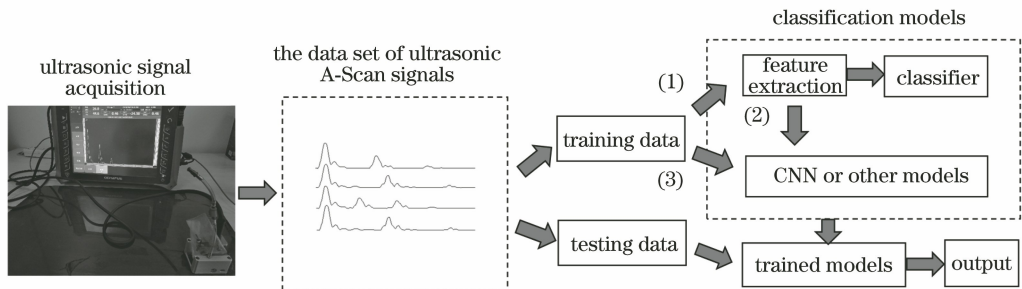


图1 CFRP缺陷类型自动识别的整体流程

Fig. 1 Overall process of automatic identification of CFRP defect types

3 U-1DCNN 模型

超声检测是 CFRP 无损检测中常用的方法之一, A-Scan 信号是超声检测中表示检测结果的基本形式, 是一维非平稳信号, 表示超声波信号幅度与传播时间的关系, 有经验的检测人员可通过 A-Scan 信号判断缺陷类型、深度等信息。一维 CNN 模型可通过卷积层、激活函数层、池化层等提取不同缺陷类型的 A-Scan 信号特征, 并且 CNN 提取特征的节点在一定程度上会保留信号的相对位置信息^[13], 因此本文利用一维 CNN 对原始超声 A-Scan 信号进行特征提取, 实现 CFRP 缺陷类型自动识别。

3.1 U-1DCNN 结构

U-1DCNN 模型包括多卷积块并行操作以及一维残差单元堆叠连接, 结构如图 2 所示。数据输入后, 首先通过多卷积块进行特征初步提取, 输入数据为一维数据, U-1DCNN 提取的特征也是一维的。卷积核的大小影响提取的特征, 卷积核过小会导致输入信号的相关性信息丧失, 过大虽然可以较好地保留相关性信息, 但是会造成信号的细节缺失^[16], 并且会使网络参数增多, 不利于网络加深。因此, 在第一层选取 1×20 的卷积核后, 后续卷积层的卷积核尺寸会逐渐减小。

A-Scan 信号输入后, U-1DCNN 模型首先采用 3 个卷积块并行进行卷积操作的结构实现特征的提

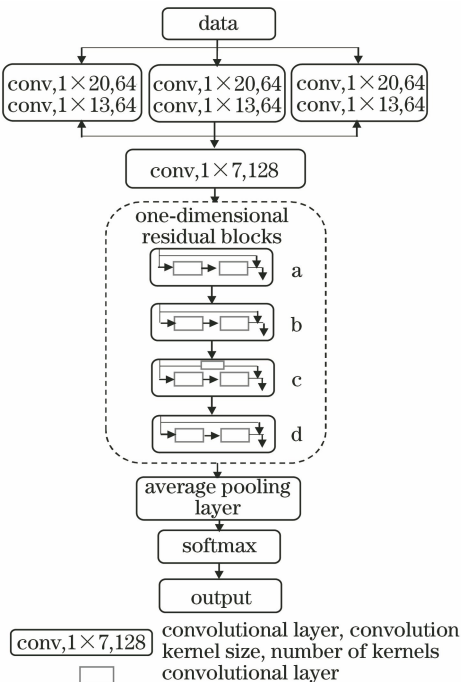


图 2 U-1DCNN 结构图

Fig. 2 Structure diagram of U-1DCNN

取, 多卷积块同时操作可获得更加丰富的特征信息, 使得提取的特征更加全面。多卷积块结构如图 3 所示, 3 个卷积块同时对 A-Scan 信号提取特征, 并将提取的特征进行融合, 输入到卷积核尺寸为 1×7 的卷积层继续进行卷积操作。当网络层数加深时, CNN 便会出现性能退化和训练难度增加问题, 使得 CNN 不能较好地发挥其强大的分类能力。He 等^[17]于 2015 年提出 ResNet, 很好地改善了因网络深度增加带来的性能退化问题, 简化了网络的训练过程。本研究在使用多卷积块同时提取特征后, 引入 ResNet 的残差单元, 将其改进为一维残差单元, 并堆叠连接, 如图 2 的虚线部分所示。残差单元结构如图 4 所示, 其中 BN/ReLU 表示批标准化层与激活函数层, 利用两层卷积层以及激活函数层来实现网络特征提取和非线性映射; 通过 shortcut 连接, 将两个分支相应特征数据进行融合; 最后通过 ReLU 层进行非线性激活, 以此构成一个残差单元, 即

$$y = F(x, \{W_i\}) + x, \quad (1)$$

式中: x 与 y 分别为残差单元的输入与输出; $F(x, \{W_i\})$ 表示要学习的残差映射, 此时, x 与 $F(x, \{W_i\})$ 的维数必须相等, 当维数不同时, 通过图 4(b)所示的结构连接, 利用卷积核为 1×1 的卷积操作进行线性投影, 实现维度匹配。该过程可表示为

$$y = F(x, \{W_i\}) + W_s x. \quad (2)$$

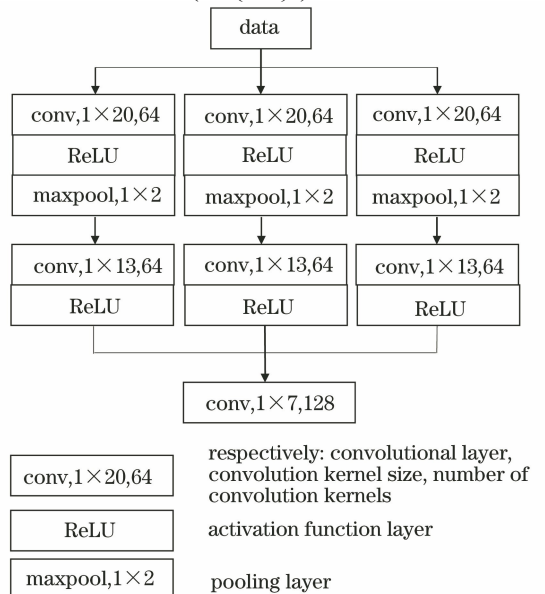


图 3 多卷积块并行结构图

Fig. 3 Structure diagram of parallel structure of multi-convolution blocks

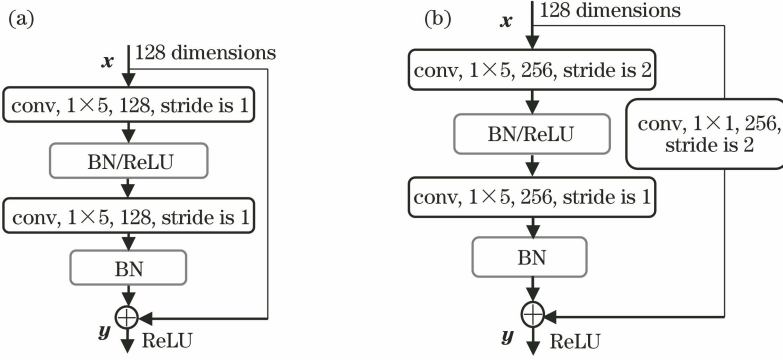


图 4 残差单元结构图。(a)不需匹配维度;(b)需匹配维度

Fig. 4 Structure diagrams of the residual units. (a) No matching dimensions; (b) matching dimensions

图 2 中,残差单元 a 与 b 均含有 128 个卷积核,连接方式如图 4(a)所示;c 与 d 均含有 256 个卷积核,b 与 c 连接时,需要匹配维度,连接方式如图 4(b)所示。在残差单元堆叠连接后,学习到的特征通过平均池化层输入到全连接层,经过 softmax 层实现分类。网络训练采用动量随机梯度下降法,经过多次不断更新权值与偏置,使验证数据集的分类误差更小,以此来实现 CFRP 的缺陷分类。

3.2 一维卷积计算

U-1DCNN 模型的输入数据是一维超声 A-Scan 信号,信号输入卷积层后,经过卷积运算得到特征信号,特征信号也是一维的。图 5 表示第 $l-1$ 层第 g 个特征信号与卷积核进行卷积运算,得到第

l 层第 h 个特征信号的过程, W^l 是一维卷积核,尺寸为 $1 \times k$, $l-1$ 层的第 g 个特征信号为 $\mathbf{x}_g^{l-1} = \{x_{g1}^{l-1}, \dots, x_{gm}^{l-1}, \dots, x_{gL}^{l-1}\}$, L 是特征信号的长度。图 5 中, $\mathbf{x}_{g(m:k-1)}^{l-1}$ 是长为 k 的特征信号,经过卷积得到 x_{hm}^l ,表示为(3)式,*表示卷积操作, b^l 为偏置; x_{hm}^l 经过非线性激活,得到如(4)式所示的形式,本研究使用的非线性激活函数 $f(\cdot)$ 为 ReLU,表达式为(5)式;此时可得到第 l 层第 h 个特征信号,表示为(6)式。

$$x_{hm}^l = W^l * \mathbf{x}_{g(m:k-1)}^{l-1} + b^l, \quad (3)$$

$$x_{hm}^l = f(W^l * \mathbf{x}_{g(m:k-1)}^{l-1} + b^l), \quad (4)$$

$$f(z) = \begin{cases} z, & z > 0 \\ 0, & z \leq 0 \end{cases}, \quad (5)$$

$$\mathbf{x}_h^l = (x_{h1}^l, x_{h2}^l, \dots, x_{hm}^l, \dots, x_{hs}^l). \quad (6)$$




图 5 一维卷积计算示意图

Fig. 5 Schematic of one-dimensional convolution calculation

3.3 贝叶斯优化

目前,主要的调参方法分为手动调参法和自动调参法,本研究使用贝叶斯优化方法自动调参,通过最大程度地减小对验证数据集的分类误差确定 U-1DCNN 的超参数。3.1 节已叙述 U-1DCNN 的网络结构,包括网络层数、卷积核尺寸等参数,除此之外,学习率以及随机梯度下降动量参数也是影响网络性能的参数,因此使用贝叶斯优化方法进行学习

率以及随机梯度下降动量参数的优选。设 P 为 U-1DCNN 的超参数空间,其包括学习率 α 和随机梯度下降动量参数 μ , F 是贝叶斯优化方法对 U-1DCNN 进行超参数优选的目标函数,最终需要寻找使目标函数 F 最优的点 p^* ,即

$$F : P(\alpha, \mu) \subset \mathbf{R}^2, \quad (7)$$

$$p^* = \arg \min_{p^* \in P} F, \quad (8)$$

式中: $p^* \in P$ 。

4 实验与分析

4.1 样本采集及数据集建立

目前,超声 A-Scan 信号分类问题尚未有公共的数据集可供使用。本文针对 CFRP 材料缺陷分

类问题,使用超声相控阵仪器 OmniScan_MX2 对 CFRP 试块进行检测,得到 A-Scan 信号(分层、气孔以及无缺陷三类),构建数据集,其中训练样本为 8000 个,测试样本为 2400 个,用于实验的 CFRP 材料规格以及信号采集数量分布如表 1 所示。

表 1 CFRP 试块规格及数据集组成

Table 1 Specifications of CFRP test blocks and dataset composition

CFRP test blocks	Test block 1		Test block 2		Test block 3
Number of layers	32		32		32
Thickness of test blocks /mm	4		4		4
	Using polytetrafluoroethylene (PTFE) films (thickness is 0.25mm) to simulate delamination;		Using PTFE films (thickness is 0.25mm) to simulate delamination;		Adding hollow glass microspheres to simulate gas cavity
Distribution of defects	a total of 30 defects, located at 2nd to 31st layers		defect shapes; square and circle		
Defect type in the dataset	Delamination	Non-defect	Delamination	Non-defect	Gas cavity
Number of defects in the dataset	1300	1300	3900	1300	2600

4.2 实验内容与结果分析

本文构建 U-1DCNN 对超声 A-Scan 信号进行分类,为了加快网络收敛速度,将原始 A-Scan 信号在 U-1DCNN 数据输入层进行数据标准化,然后利用一维 CNN 自动提取超声 A-Scan 信号中包含的缺陷类型特征。完整的超声 A-Scan 信号包括始波、缺陷回波以及底波,缺陷类型不同,缺陷回波不同,回波包含的缺陷类型信息是实现缺陷分类的依据。

为了验证 U-1DCNN 对于超声 A-Scan 信号自动分类的有效性,将 U-1DCNN 与 BP 神经网络和二维卷积神经网络缺陷分类方法进行对比,其中 BP 神经网络的特征提取依据文献[3]与文献[18],分别记为 BP+WPT 和 BP+SF,二维 CNN 模型采用文献[19]的特征提取方式,CNN 结构与 U-1DCNN 类似,记为 CNN+STFT。

1) 评价指标

为了验证各个方法的分类效果,取准确率、精确率(P_{rec})、召回率(R)、 F_1 值作为评价指标,其中 F_1 值是指模型精确率和召回率的调和平均值。在分类问题中,将测试样本根据真实类别与模型预测类别的组合划分为真阳性(T_P)、真阴性(T_N)、假阳性(F_P)和假阴性(F_N)。 T_P 表示将阳性样本识别正确的数量, F_N 表示将阳性样本识别错误的数量, F_P 表示将阴性样本识别错误的数量, T_N 表示将阴性样本识别正确的数量。

$$P_{rec} = \frac{T_P}{T_P + F_P}, \quad (9)$$

$$R = \frac{T_P}{T_P + F_N}, \quad (10)$$

$$F_1 = \frac{2 \times P_{rec} \times R}{P_{rec} + R}. \quad (11)$$

2) 超参数优选

贝叶斯优化算法如图 6 所示, D_{t-1} 是 $t-1$ 个观测数据构成的数据集,算法根据最大化采集函数来选择下一个最有“潜力”的评估点 p_t ^[20],将该点加入到样本集中并采用高斯过程来更新目标函数 F 的后验分布;在后验分布的基础上,不断寻找最大化采集函数的极值点,重复执行该过程直到达到迭代次数上限,以此来寻找最优化目标函数 F 的最佳点。U-1DCNN 的超参数优选范围分别设置如下:学习率为[0.0001, 0.1],动量参数为[0.8, 0.97],贝叶斯优化方法经过 40 次迭代之后,超参数自动选取学习

```

1 for  $t=1,2, \dots$ , do
2 The sampling points at time  $t$  are obtained by optimizing
the acquisition function  $u$ ,  $p_t \leftarrow \arg \max_p u(p; D_{t-1})$ ;
3 Evaluate the objective function value  $q_t \leftarrow F(p_t)$ ;
4 Updating sample collection  $D_t \leftarrow D_{t-1} \cup (p_t, q_t)$ ,
and updating the posterior distribution of  $F$ ;
5 end for

```

图 6 贝叶斯优化算法

Fig. 6 Bayesian optimization algorithm

率为 0.00070, 动量参数为 0.83218, 以此作为后续实验的超参数。

3) 可视化分析

U-1DCNN 直接从输入的超声一维 A-Scan 信号中提取特征, 图 7 所示为 U-1DCNN 模型的卷积层激活可视化, 将激活值归一化, 使其置于 0~1 之间, 白色表示正激活。图 8 所示为 U-1DCNN 的特

征降维可视化。由图 7 可知, 不同卷积层提取的特征不同, 浅层卷积层特征尺寸较大, 与原始数据相似, 且可以看出激活较明显的部分大致位于缺陷回波的位置, 多个卷积块提取的特征各有差异。随着网络层数增加, 特征图尺寸越来越小, 内容越来越抽象。由图 8 可知, 随着网络层数增加, 同一类别的特征会逐渐聚拢, 不同类别的特征会逐渐区分。

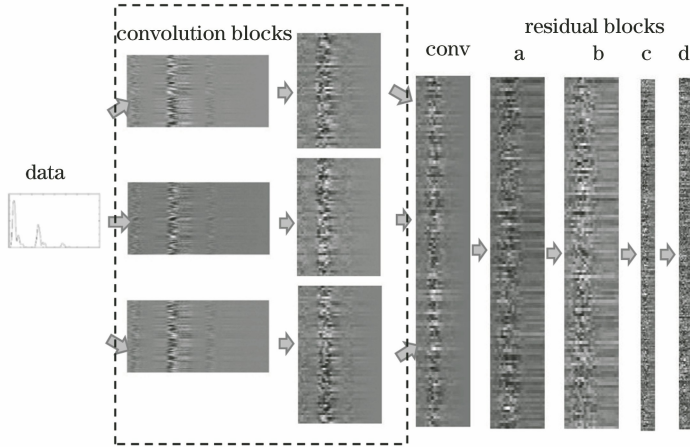


图 7 U-1DCNN 卷积层激活可视化

Fig. 7 Visualization of the activation from U-1DCNN convolutional layers

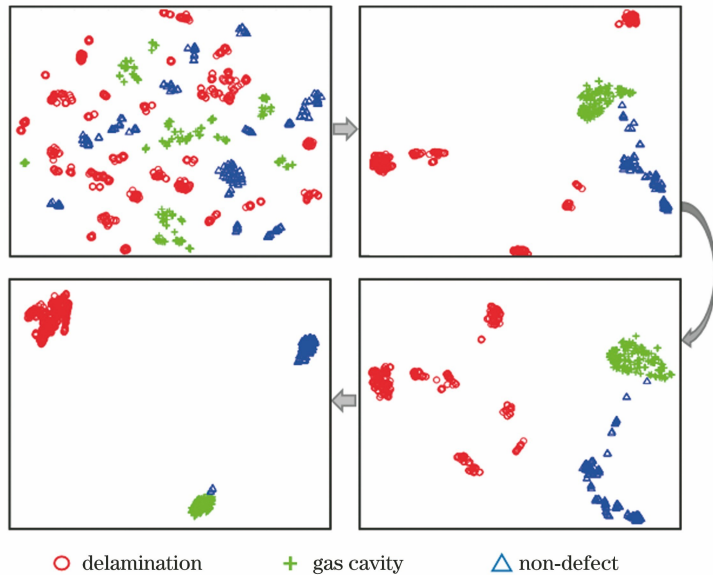


图 8 U-1DCNN 特征的降维可视化

Fig. 8 Dimensionality reduction visualization of U-1DCNN features

4) 实验结果与分析

图 9 所示为不同实验中每种缺陷类型的识别准确率比较, 表 2 显示了不同方法对超声信号分类的评价指标比较。在分层、气孔、无缺陷三种类型的识别准确率比较上, BP 神经网络的两个实验(BP+WPT、BP+SF)除在气孔上的识别准确率高于 CNN+STFT, 其余类型识别准确率均低于 CNN 的两个实验

(CNN+STFT、U-1DCNN); 图 9 中对比实验对测试样本总体识别准确率分别为 85.04%、93.08%、98.29%、99.50%, 由此可知, BP 神经网络的分类准确率低于 CNN 方法, 因此利用 CNN 模型进行缺陷类型识别的效果优于 BP 神经网络方法。从图 9 可以看出, 在 BP+WPT、BP+SF 实验中, 对于无缺陷类型的 A-Scan 信号识别准确率较低。结合表 2 可知, 分层

缺陷与无缺陷识别时会相互干扰,这是因为计算特征之前需要对缺陷回波进行截取,无缺陷类型的截取范围与分层缺陷相同,部分分层缺陷的深度接近底面,截取的分层缺陷回波可能与无缺陷底面回波类似,计算的特征值接近,导致识别出现错误。

在 CNN+STFT 实验中,气孔识别准确率低于其他两种类型,但 U-1DCNN 模型对气孔的识别准确率高于 CNN+STFT 方法,因为 U-1DCNN 是将完整的 A-Scan 信号作为输入,在网络训练过程中不会出现人为干预特征提取,由一维 CNN 自动提取特征,从大量 A-Scan 信号中学习有用信息,以获得更好的识别效果。虽然 U-1DCNN 对于无缺陷的

识别准确率低于 CNN+STFT 实验,但其整体识别准确率比 CNN+STFT 实验高了 1.21 个百分点,并且从表 2 可以看出,U-1DCNN 是将无缺陷类型识别为其他类型,在实际检测情况中,将有缺陷判定为无缺陷的代价远远大于将无缺陷判定为有缺陷。在缺陷分类速度上,采用对 2400 个测试样本完全识别所需时间来比较,由于 BP 神经网络准确率低于 CNN 方法,所以不考虑 BP 神经网络的测试时间对比,仅比较 CNN 方法。CNN+STFT 识别 2400 个样本所需时间大约为 270 s,而 U-1DCNN 识别时间约为 15 s,用时更短。整体来看,U-1DCNN 识别效果优于 CNN+STFT。

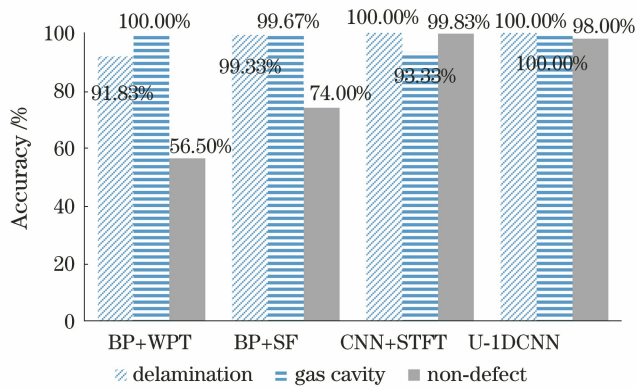


图 9 不同方法的分类准确率比较

Fig. 9 Comparison of classification accuracy of different methods

表 2 不同方法评价指标对比

Table 2 Comparison of evaluation indicators of different methods

Defect type	Evaluation indicator	BP+WPT	BP+SF	CNN+STFT	U-1DCNN
Delamination	$P_{rec} / \%$	80.85	88.30	96.70	100.00
	$R / \%$	91.83	99.33	100.00	100.00
Gas cavity	$P_{rec} / \%$	97.72	99.01	100.00	98.04
	$R / \%$	100.00	99.67	93.33	100.00
Non-defect	$P_{rec} / \%$	80.14	99.55	100.00	100.00
	$R / \%$	56.50	74.00	99.83	98.00
	$P_{rec} / \%$	86.24	95.62	98.90	99.36
Average value	$R / \%$	82.78	91.00	97.72	99.33
	$F_1 / \%$	84.47	93.25	98.31	99.34
Error rate / %		14.96	6.92	1.71	0.50

5 总 结

U-1DCNN 将 A-Scan 信号作为输入进行训练,自动提取超声 A-Scan 信号中与缺陷类型区分相关的信息,通过多卷积块并行以及一维残差单元堆叠连接提取特征,实现 A-Scan 信号自动分类,并且利用贝叶斯优化算法优选 U-1DCNN 网络的

超参数,节省了调参时间。通过与其他分类方法对比,证明了 U-1DCNN 在 CFRP 缺陷类型自动区分上的有效性,准确率为 99.50%,且在测试样本的分类速度上明显优于二维 CNN 方法,在缺陷自动分类中有较好的应用前景。同时,由实验分析可知,不同方法可能对某一种缺陷类型的识别效果较好,未来可以考虑将多个分类模型融合,以获

得更好的缺陷识别效果。

参 考 文 献

- [1] Shen Z, Zhang X J. An introduction to design and verification for composite aircraft structures [M]. Shanghai: Shanghai Jiao Tong University Press, 2011:5-7.
沈真, 张晓晶. 复合材料飞机结构强度设计与验证概论[M]. 上海: 上海交通大学出版社, 2011: 5-7.
- [2] Liu S P, Liu F F. Nondestructive testing technology in aviation industry and its progress [J]. Nondestructive Testing, 2017, 39(6): 56-60.
刘松平, 刘菲菲. 航空工业中的无损检测技术及其进展[J]. 无损检测, 2017, 39(6): 56-60.
- [3] Li J, Guo W, Yang X X, et al. A flaw classification method for ultrasonic phased array inspection of CFRP[J]. Journal of Tianjin University (Science and Technology), 2015, 48(8): 750-756.
李健, 郭薇, 杨晓霞, 等. 超声相控阵检测 CFRP 缺陷识别方法[J]. 天津大学学报(自然科学与工程技术版), 2015, 48(8): 750-756.
- [4] Yang P, Li Q F. Wavelet transform-based feature extraction for ultrasonic flaw signal classification[J]. Neural Computing and Applications, 2014, 24(3/4): 817-826.
- [5] Chen H J, Liu H, Wang X Y, et al. Research on feature extraction and classification of ultrasonic flaw [J]. International Journal of Circuits, Systems and Signal Processing, 2015, 9: 362-372.
- [6] Leo M, Looney D, D'Orazio T, et al. Identification of defective areas in composite materials by bivariate EMD analysis of ultrasound[J]. IEEE Transactions on Instrumentation and Measurement, 2012, 61(1): 221-232.
- [7] Qiao T, Su H S, Liu G H, et al. Object detection algorithm based on improved feature extraction network [J]. Laser & Optoelectronics Progress, 2019, 56(23): 231008.
乔婷, 苏寒松, 刘高华, 等. 基于改进的特征提取网络的目标检测算法[J]. 激光与光电子学进展, 2019, 56(23): 231008.
- [8] Zhang W, Lü X Q, Wu L, et al. Advances in classification technology based on typical medical images[J]. Laser & Optoelectronics Progress, 2018, 55(12): 120007.
张薇, 吕晓琪, 吴凉, 等. 基于典型医学图像的分类技术研究进展[J]. 激光与光电子学进展, 2018, 55(12): 120007.
- [9] Wang Y, Zhu L Q, Yu Z J, et al. Segmentation and recognition algorithm for high-speed railway scene [J]. Acta Optica Sinica, 2019, 39(6): 0610004.
王洋, 朱力强, 余祖俊, 等. 高速铁路场景的分割与识别算法[J]. 光学学报, 2019, 39(6): 0610004.
- [10] Lu R S, Wu A, Zhang T D, et al. Review on automated optical (visual) inspection and its applications in defect detection [J]. Acta Optica Sinica, 2018, 38(8): 0815002.
卢荣胜, 吴昂, 张腾达, 等. 自动光学(视觉)检测技术及其在缺陷检测中的应用综述[J]. 光学学报, 2018, 38(8): 0815002.
- [11] Ye J X, Ito S, Toyama N. Computerized ultrasonic imaging inspection: from shallow to deep learning [J]. Sensors, 2018, 18(11): 3820.
- [12] Meng M, Chua Y J, Wouterson E, et al. Ultrasonic signal classification and imaging system for composite materials via deep convolutional neural networks[J]. Neurocomputing, 2017, 257: 128-135.
- [13] Zhu H J, Wang X Q, Rui T, et al. Machinery fault diagnosis based on shift invariant CNN[J]. Journal of Vibration and Shock, 2019, 38(5): 45-52.
朱会杰, 王新晴, 芮挺, 等. 基于平移不变 CNN 的机械故障诊断研究[J]. 振动与冲击, 2019, 38(5): 45-52.
- [14] Virupakshappa K, Marino M, Oruklu E. A multi-resolution convolutional neural network architecture for ultrasonic flaw detection [C] // 2018 IEEE International Ultrasonics Symposium (IUS), October 22-25, 2018. Kobe, Japan. New York: IEEE, 2018: 8579888.
- [15] Zhou Z G, Sun G K. New progress of the study and application of advanced ultrasonic testing technology [J]. Journal of Mechanical Engineering, 2017, 53(22): 1-10.
周正干, 孙广开. 先进超声检测技术的研究应用进展[J]. 机械工程学报, 2017, 53(22): 1-10.
- [16] Zhu X X, Liu F S, Zhang C, et al. Research on in-car speech recognition based on one dimensional convolutional neural networks [J]. Microelectronics & Computer, 2017, 34(11): 21-25.
朱锡祥, 刘凤山, 张超, 等. 基于一维卷积神经网络的车载语音识别研究[J]. 微电子学与计算机, 2017, 34(11): 21-25.
- [17] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016. Las Vegas,

- NV, USA. New York: IEEE, 2016: 770-778.
- [18] Wang L, Zhou Z J, Hu C H, et al. Ultrasonic testing defect recognition based on belief-rule-base and evidential reasoning[J]. *China Measurement & Testing Technology*, 2017, 43(4): 6-10, 67.
王力, 周志杰, 胡昌华, 等. 基于置信规则和证据推理的超声检测缺陷识别[J]. *中国测试*, 2017, 43(4): 6-10, 67.
- [19] Wang L H, Xie Y Y, Zhou Z X, et al. Motor fault diagnosis based on convolutional neural networks[J]. *Journal of Vibration, Measurement & Diagnosis*, 2017, 37(6): 1208-1215, 1283.
王丽华, 谢阳阳, 周子贤, 等. 基于卷积神经网络的异步电机故障诊断[J]. *振动.测试与诊断*, 2017, 37(6): 1208-1215, 1283.
- [20] Cui J X, Yang B. Survey on Bayesian optimization methodology and applications [J]. *Journal of Software*, 2018, 29(10): 3068-3090.
崔佳旭, 杨博. 贝叶斯优化方法和应用综述[J]. *软件学报*, 2018, 29(10): 3068-3090.