

一种多源特征融合深度学习模型及复杂构件缺陷类型识别方法

程虎跃¹, 刘 贞², 史志光¹, 王永红², 姜洪权¹, 杨得焱¹, 高建民¹, 支泽林¹
(1. 西安交通大学 机械制造系统工程国家重点实验室, 西安 710049;
2. 西安航天发动机有限公司, 西安 710100)

摘 要: 复杂构件内部缺陷的类型识别对于保证装备制造质量及安全可靠运行具有重要的意义。针对现有深度学习模型用于缺陷类型识别时存在局部特征提取较差、缺乏考虑缺陷经验特性以及特征信息丢失的问题,提出了一种融合先验特征、全局特征以及 ReliefF-Pooling 策略的缺陷类型识别方法;实现了缺陷几何、纹理等先验特征与卷积神经网络全局特征的融合分析,并通过构建基于 ReliefF-Pooling 的特征优化方法,实现不同权重特征信息优化利用;最后,以某航天企业实际的复杂构件内部缺陷的射线检测为例进行了验证。试验结果表明,所提方法可以有效提升复杂构件内部缺陷的类型识别精度。

关键词: 缺陷类型识别;射线检测;深度学习;先验特征
中图分类号: TP391;TG115.28 **文献标志码:** A **文章编号:** 1000-6656(2023)02-0012-07

A deep learning model based on multi-source feature fusion and defect type recognition method for complex components

CHENG Huyue¹, LIU Zhen², SHI Zhiguang¹, WANG Yonghong², JIANG Hongquan¹, YANG Deyan¹,
GAO Jianmin¹, ZHI Zelin¹
(1. State Key Laboratory for Manufacturing Systems Engineering, Xi'an Jiaotong University, Xi'an 710049, China;
2. Xi'an Space Engine Co., Ltd., Xi'an 710100, China)

Abstract: The internal defect type recognition of complex components is of great significance to ensure equipment manufacturing quality and safe and reliable operation. Aiming at the problems of poor local feature extraction, lack of considering the empirical characteristics of defects and loss of feature information in the existing deep learning model for defect type recognition, a defect type recognition method based on prior features, global features and ReliefF-Pooling strategy is proposed. The fusion analysis of prior features such as defect geometry, texture and global features of convolutional neural network (CNN) is realized, and the feature optimization method based on ReliefF-Pooling is constructed to optimize the utilization of feature information with different weights. Finally, as an example, the actual radiographic testing of internal defects in complex components in an aerospace enterprise is used to verify the proposed method. The experimental results show that the proposed method can effectively improve the type recognition accuracy of internal defects in complex components.

Key words: defect type recognition; radiographic testing; deep learning; priori feature

收稿日期: :2022-08-05
作者简介:程虎跃(1998—),男,博士研究生,主要研究方向为机器视觉与智能制造、无损检测与缺陷识别技术
通信作者:姜洪权(1978—),男,博士,副教授,博士生导师,主要研究方向为制造质量及服役质量理论与提升技术、工业大数据分析与应用,jhqxjtu@163.com

在航空、航天、能源等领域的大型复杂装备制造中,存在一类 3D 打印及铸造复杂构件,其内部缺陷主要采用射线技术进行检测,并由人工对射线检测图像进行识别^[1]。复杂构件多为关键部件,故对其缺陷检出率有较高的要求,且要求确定缺陷的类型,

以利于质量判定。现有人工识别缺陷类型方式效率低、主观性强、误判率高,是制约当前复杂构件高效制造的瓶颈。因此,研究复杂构件缺陷类型的射线检测图像智能识别方法,对提升缺陷检测能力及装备质量管控能力具有重要意义。

当前,基于射线检测图像的缺陷类型识别方法从发展历程上大致可以分为两个阶段:传统缺陷类型识别方法和基于深度学习的缺陷类型识别方法^[2]。传统缺陷类型识别方法^[3]一般包括缺陷分割^[4]、缺陷特征提取与选择^[5]、缺陷类型识别^[6]三个步骤。传统方法是典型的“串联”方式,具有方法可解释性强、缺陷先验特征明确等优势,但对各个步骤的准确性要求高,方法的泛化能力差,容易降低类型识别的最终准确性。

近年来,随着深度学习等理论的发展,基于卷积神经网络(CNN)等人工智能的缺陷类型识别方法得到了广泛的关注^[7-9]。相较于传统缺陷类型识别方法,该方法不仅可以避免“串联”方式中误差对后续识别精度的影响,而且能够实现“端到端”的缺陷类型识别,泛化能力较好。然而,由于复杂构件的射线检测图像背景复杂、缺陷灰度对比度低、且不同类型缺陷的差异很小,现有深度学习模型仅仅是提取

了缺陷抽象特征(全局),缺乏有效利用缺陷的先验特征(局部),而使得部分缺陷的类型识别效果不佳。

针对以上问题,提出了一种多源特征融合深度学习模型及复杂构件缺陷类型识别方法。首先,通过构建先验特征(几何特征与纹理特征),并与传统CNN提取的特征进行融合,提升了模型对缺陷全局特征及局部具体特征的综合提取能力;其次,为解决多类特征权重计算问题,提出了考虑特征权重的ReliefF-Pooling方法;最后,以某航天企业实际的复杂构件缺陷为例对所提方法进行说明和验证。

1 多源特征融合深度学习模型的缺陷类型识别方法

1.1 综合先验特征融合与 ReliefF-Pooling 的深度学习模型设计

提出的综合先验特征融合与 ReliefF-Pooling 策略的深度学习模型结构如图 1 所示,图中 M 为 CNN 提取的特征图; V 为特征图经过 ReliefF-Pooling 后的特征向量; G_p 为第一先验特征向量; F_p 为纹理先验特征向量。其主要包括 3 个模块,即先验特征提取模块、CNN 特征提取模块、特征融合与分类模块。

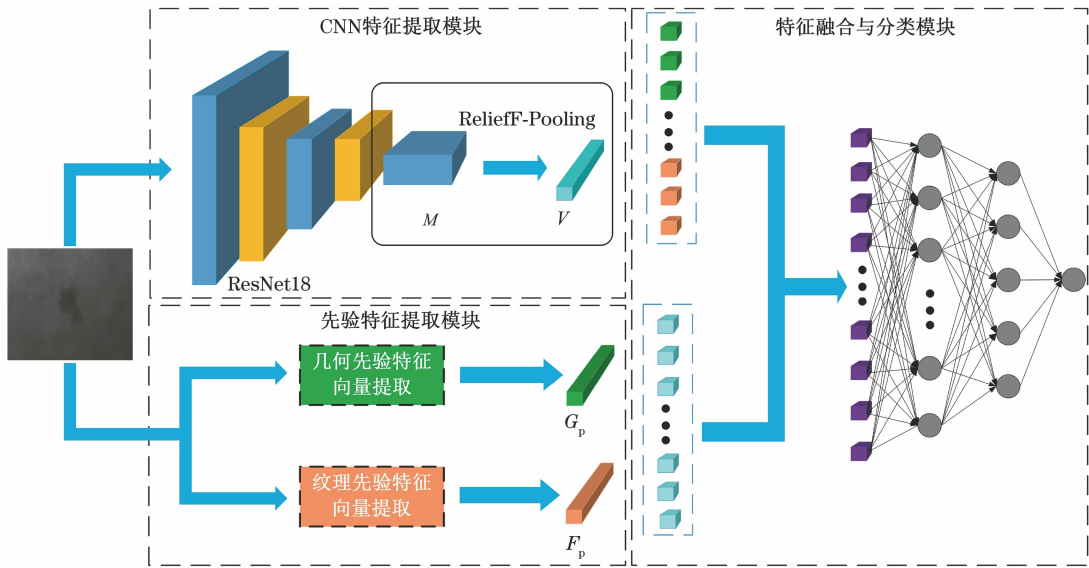


图 1 综合先验特征融合与 ReliefF-Pooling 的深度学习模型结构

1.2 先验特征提取模块

1.2.1 几何先验特征向量构建

根据标准 HB 6573—1992《熔模钢铸件用标准参考射线底片》中射线检测常见缺陷的类型定义,复杂构件内部常见缺陷类型分为气孔、夹杂、疏松、裂纹和未熔合等 5 类(见图 2)。

各类缺陷的主要特点与区别如下:① 气孔缺陷表现为圆形或椭圆形的黑色斑点状,轮廓光滑且无棱角,中心区域黑度分布较大,并逐渐向边缘减弱;② 夹杂缺陷呈现块状特点,轮廓呈现带明显棱角的不规则多边形,内部灰度分布不均;③ 疏松缺陷一般为漫射状的暗区、不连续的细小长条形或者呈细线状的分




图2 复杂构件典型内部缺陷示例

布;④ 裂纹缺陷表现为对比度较高的黑色丝线状,且端部尖细、端头方向出现丝状阴影延伸;⑤ 未熔合缺陷表现为宽度不一、黑度变化不均匀的条状,且分布呈现出断续模糊、轮廓边界不规则的特点。

可以看出,不同类型缺陷具有不同的明显特点^[11],这些特点是经验丰富的技术人员具有的核心知识。基于以上分析,构建了如表1所示的6个几何先验特征作为缺陷的第一先验特征向量 \mathbf{G}_p ,即

$$\mathbf{G}_p=[g_1 \ g_2 \ g_3 \ g_4 \ g_5 \ g_6]^T \quad (1)$$

表1中, W_z 为缺陷长度方向距离离末端处 z , L 的实际宽度, z 为缩放比例,此处取 $1/4$; S 为缺陷的实际像素面积; P_x 为缺陷长度方向上的像素点; W_{P_x} 为 P_x 处缺陷的实际宽度。

表1 缺陷几何先验特征

特征	定义	表达式
缺陷长度 g_1	缺陷最小外接矩形的长	L
缺陷宽度 g_2	缺陷最小外接矩形的宽	W
缺陷纵横比 g_3	缺陷长度与宽度之比	L/W
缺陷尖锐度 g_4	沿长度两端缺陷的尖锐度	$\arctan[W_z/(z \cdot L)]$
缺陷边缘离散度 g_5	缺陷边缘的变化	$\frac{1}{L} \sum_{p_x=0}^{L-1} W_{p_x+1} - W_{p_x} $
缺陷饱和度 g_6	缺陷实际面积与缺陷最小外接矩形面积之比	$S/(L \cdot W)$

1.2.2 纹理先验特征向量构建

为了更好地表征气孔、夹杂与疏松以及裂纹、未熔合之间的纹理区别先验信息,笔者构建了基于纹理先验特征的第二先验特征向量,并且采用灰度共生矩阵^[11]实现缺陷的纹理特征提取,来表征图像的灰度空间特性。

一般对于灰度级为 Q 级的图像 I , 其灰度共生矩阵 \mathbf{P} 可描述为

$$\begin{aligned} P(i, j, d, \theta) &= p[I(x, y) = i, \\ I(x + d \cos \theta, y + d \sin \theta) &= j] \end{aligned} \quad (2)$$

式中: $I(x, y)$ 为图像 I 在像素点 (x, y) 处的灰

度; $i, j = 1, 2, \dots, Q$; d 为两个像素点在图像中的欧氏距离; θ 为两个像素点在图像中的方向角度; $p[I(x, y) = i, I(x + d \cos \theta, y + d \sin \theta) = j]$ 代表距离为 d 、方向为 θ 、灰度值为 i 和 j 的一对像素对出现的概率。

笔者选取角度 $\theta = 0^\circ$, 距离 $d = 1$ 的像素计算灰度共生矩阵,即 $P(i, j)$ 代表 $P(i, j, 1, 0^\circ)$, 然后计算该矩阵的统计特征量获得缺陷的纹理特征。

(1) 能量

能量用于度量缺陷纹理灰度变化的程度,定义为

$$f_1 = \sum_{i=1}^Q \sum_{j=1}^Q [P(i, j)]^2 \quad (3)$$

(2) 反差分矩阵

反差分矩阵用于体现缺陷纹理局部变化的大小,可定义为

$$f_2 = \sum_{i=1}^Q \sum_{j=1}^Q \frac{1}{1 + (i - j)^2} P(i, j) \quad (4)$$

(3) 相关性

相关性可用于表现缺陷局部灰度的相关程度,可定义为

$$f_3 = \sum_{i=1}^Q \sum_{j=1}^Q \frac{(i - u_i)(j - u_j)P(i, j)}{\sigma_i \sigma_j} \quad (5)$$

式中:

$$\begin{aligned} u_i &= \sum_{i=1}^Q \sum_{j=1}^Q i \cdot P(i, j); \\ u_j &= \sum_{j=1}^Q \sum_{i=1}^Q j \cdot P(i, j); \\ \sigma_i &= \sum_{i=1}^Q (i - u_i)^2 \sum_{j=1}^Q P(i, j); \\ \sigma_j &= \sum_{j=1}^Q (j - u_j)^2 \sum_{i=1}^Q P(i, j). \end{aligned}$$

(4) 对比度

对比度用来反映缺陷纹理深浅及其清晰度,可定义为

$$f_4 = \sum_{i=1}^Q \sum_{j=1}^Q (i - j)^2 P(i, j) \quad (6)$$

(5) 熵

熵用于描述缺陷纹理以及分布的复杂性以及非均匀性,可定义为

$$f_5 = - \sum_{i=1}^Q \sum_{j=1}^Q P(i, j) \lg[P(i, j)] \quad (7)$$

将以上5个参数作为缺陷纹理特征,并构建纹理先验特征向量 \mathbf{F}_p ,即

$$\mathbf{F}_p=[f_1 \ f_2 \ f_3 \ f_4 \ f_5]^T \quad (8)$$

1.3 考虑特征重要性的 CNN 特征提取模块

如图 1 所示,在 CNN 特征提取模块中,笔者提出了一种基于 ReliefF-Pooling 的 CNN 特征提取模块,ReliefF 算法^[12]是由 KONONEILL 在 Relief 算法基础上提出的一种解决多类问题的特征权重计算方法,其核心思想是根据同类与异类样本在特征距离上的大小,衡量特征和类别之间的相关性,并据此赋予特征不同的权重。

对于训练集 D ,样本抽样次数为 λ ,特征权重阈值为 μ ,最邻近样本个数为 k ,输出各个特征的权重 W ,其 ReliefF 流程如下:① 置所有特征权重初始值为 0;② 对于每次抽样,从 D 中随机选择一个样本 R ,然后在样本 R 的同类和每个异类样本中各寻找

$$\text{diff}(f,R,H_j)=\begin{cases} \frac{|R[f]-H_j[f]|}{\max(f)-\min(f)}, & f \text{ 连续} \\ 0, & f \text{ 不连续,且 } R[f]=H_j[f] \\ 1, & f \text{ 不连续,且 } R[f]\neq H_j[f] \end{cases} \quad (10)$$

式中: $\max(f)$ 和 $\min(f)$ 分别为样本 R 的特征 f 的最大值和最小值; $R[f]$ 为样本 R 的特征 f 的值; $H_j[f]$ 为样本 H_j 的特征 f 的值。

ReliefF-Pooling 方法原理如图 3 所示,首先,将大小为 $m \times n \times c$ 特征图 M 中每个通道分别展平放入到一维向量中,产生 c 个长度为 $m \times n$ 的一维向

k 个最邻近样本 H_j 和 $M_j(C)$;③ 对于样本 R 的每个特征 f ,按照式(9)更新对应的权重。

$$W(f)=W(f)-\sum_{j=1}^k \text{diff}(f,R,H_j)/(\lambda k)+\sum_{C \neq R} \left[\frac{p(C)}{1-p(R)} \sum_{j=1}^k \text{diff}(f,R,M_j(C)) \right]/(\lambda k) \quad (9)$$

式中: $W(f)$ 为特征 f 的权重; H_j 为样本 R 同类中的第 j 个样本; $\text{diff}(f,R,H_j)$ 为样本 R 和 H_j 在特征 f 上的距离,其定义如式(10)所示; $p(C)$ 为 R 的异类样本 C 的比例; $p(R)$ 为抽取的样本 R 的比例; $M_j(C)$ 为样本 R 的异类 C 中的第 j 个样本; λ 为抽样次数。

量, c 个一维向量构成一组特征向量 V_a ;其次,对于 V_a 中的每个一维向量,采用 ReliefF 特征权重计算方法计算每个特征值对应的权重,得到带有权重的特征向量 V_β 。如果权重为正,说明该特征利于分类,保留该特征权重;如果权重为负,则说明该特征不利于分类,将其权重置为 0。

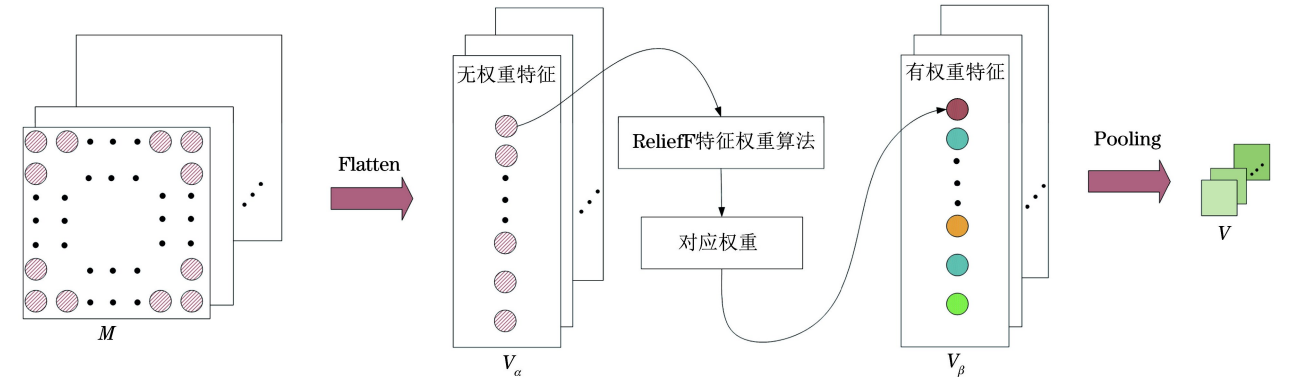


图 3 ReliefF-Pooling 方法原理示意

对于带有权重的特征向量 V_β ,对其中的每个一维向量 V_{β_i} 进行加权平均池化,其计算公式为

$$V_i=\sum_{j=1}^{m \times n} \omega(j) \times V_{\beta_i}(j) \quad (11)$$

式中: $i=1,2,3,\cdots,c$; V_i 为输出特征向量的特征值; $V_{\beta_i}(j)$ 为一维向量 V_{β_i} 在点 j 对应的特征值; $\omega(j)$ 为一维向量 V_{β_i} 在点 j 对应的特征值对应的权重。

1.4 特征融合与分类模块

如图 1 所示,特征融合与分类模块包括两个全连接层和一个输出层,对在 CNN 特征提取模块中

提取到的长度为 64 的特征向量 V 以及在先验特征提取模块中提取到的长度为 6 的几何先验特征向量 G_p 与长度为 5 的纹理先验特征向量 F_p 进行融合,采用级联融合的方式获得长度为 75 的融合特征,经过两个全连接层后,输入到输出层进行分类。

改进 CNN 模型的主要参数如表 2 所示,其中,Input 代表输入层;Conv 代表卷积层;FC 代表全连接层;Output 代表输出层,采用 Softmax 函数。所有卷积层的卷积核大小均为 3×3 ; s 为步长;填充方式为填充一层边缘像素; N 为每批次输入网络的

图片数量; w 和 h 分别为输入图像的宽和高。激活函数均采用 ReLU 函数, 优化器选用 Adam 优化器, 初始学习率为 0.01, 学习率的衰减率为 0.98, 优化后的学习率为 0.001。

表 2 改进 CNN 模型的主要参数

结构层次	输出数据大小
Input	$[N, w, h, 1]$
Conv1, $s=1$	$[N, w, h, 16]$
Conv2—Conv5, $s=1$	$[N, w, h, 32]$
Conv6, $s=2$	$[N, w/2, h/2, 64]$
Conv7—Conv9, $s=1$	$[N, w/2, h/2, 64]$
Conv10, $s=2$	$[N, w/4, h/4, 128]$
Conv11—Conv13, $s=1$	$[N, w/4, h/4, 128]$
Conv14, $s=1$	$[N, w/4, h/4, 64]$
ReliefF-Pooling	$[N, 64]$
FC1	$[N, 32]$
FC2	$[N, 16]$
Output	$[N, 5]$

2 实例说明

各模型架构及其相应改进如表 3 所示, 为了验证所提多源特征融合深度学习模型及缺陷类型识别方法的有效性, 在此将该模型(CNN4)与其他 3 种模型进行对比分析。

表 3 各模型架构及其相应改进处

模型名称	模型架构	模型改进
CNN1	ResNet18	无
CNN2	ResNet18	加入 ReliefF-Pooling
CNN3	ResNet18	加入先验特征向量
CNN4	ResNet18	文章方法

验证时, 使用数据集为某航天企业提供的复杂构件射线检测图像, 其中复杂构件采用铸造工艺制造, 包括铸铁件和铸铝件, 材料厚度为 10~30 mm, 含有裂纹、未熔合、气孔、疏松、夹杂等 5 种类型缺陷, 各类缺陷的特征分析如 1.2.1 节所述。数据集图像像素大小(长×宽)在 32×32 到 128×128 之间, 缺陷的实际大小在(长×宽)在 1.2 mm×1.2 mm 到 6.4 mm×6.4 mm 之间, 每张图片缺陷区域占比约为 70%, 共计 6 208 张图像, 其中训练集占 80%, 测试集占 20%。各类缺陷的类型及数量分布如表 4 所示, 分别使用表 3 中的 4 种模型在缺陷数据集上进行训练与测试。

为了便于比较不同模型的性能, 采用了模型精确度、召回率、F1-Score 等不同指标^[13]进行计算。

表 4 缺陷的类型及数量分布

缺陷类型	训练集数目	测试集数目
裂纹	317	79
未熔合	276	68
气孔	285	71
疏松	1 501	375
夹杂	2 589	647
合计	4 968	1 240

(1) 精确度, 表示判定为缺陷的图像中真实缺陷图像所占的比例, 可定义为

$$P = \frac{T_P}{T_P + F_P} \times 100\% \tag{12}$$

式中: T_P 为真正例的数量; F_P 为假正例的数量。 F_N 为假负例的数量。

(2) 召回率, 反映真实缺陷图像被正确判定出来的比例, 可定义为

$$R = \frac{T_P}{T_P + F_N} \times 100\% \tag{13}$$

(3) F_1 -Score, 用于综合评价精确度与召回率, 可定义为

$$F_1 = \frac{2 \times P \times R}{(P + R)} \times 100\% \tag{14}$$

CNN1 在测试集上的识别结果如图 4 所示, 可以看出, CNN1 对夹杂、气孔缺陷的分类精确度较高, 对裂纹、未熔合、疏松缺陷的分类精确度较低。这一方面原因是 CNN1 在特征提取过程中, 低层网络不能有效提取到几何特征、纹理特征等局部具体特征; 另一方面原因是在特征图映射过程中, 对裂纹、未熔合、疏松等缺陷特征存在丢失现象。

CNN2 的缺陷类型识别结果如图 5 所示, 可以看出, CNN2 的性能总体上高于 CNN1 结果, 可见加入 ReliefF-Pooling 后的模型对于多尺度缺陷可以在特征图映射过程中更好地保留特征信息, 更大化地对特征进行利用。

CNN3 的缺陷类型识别结果如图 6 所示, 可以看出, CNN3 的性能较 CNN1 性能有较大提升, 可见在模型中融入几何先验特征向量以及纹理先验特征向量可以弥补模型低层局部特征提取能力的不足, 较好地提升模型的性能; 另外 CNN3 整体识别效果均优于 CNN2 效果, 这表明虽然 CNN3 相对于 CNN2 没有使用 ReliefF-Pooling, 在特征图映射过程丢失了一部分信息, 但其在全连接层融合了先验特征, 包括缺陷的几何先验特征和纹理先验特征, 可以提取到更丰富的缺陷局部具体特征。




图 4 CNN1 方法的缺陷类型识别结果




图 5 CNN2 方法的缺陷类型识别结果




图 6 CNN3 方法的缺陷类型识别结果

CNN4(文章方法)的缺陷类型识别结果如图 7 所示,可以看出,CNN4 方法的性能整体表现最好,具有更好的分类能力;对比图 4 和图 7,文章方法(CNN4)相较于传统方法(CNN1)在精确度、召回率和 F_1 -Score 上均有提升,尤其是对于裂纹、未熔合和疏松 3 种缺陷的提升程度最高。在精确度方面,




图 7 CNN4 方法的缺陷类型识别结果

裂纹、未熔合和疏松三类缺陷分别提升了 16.91%, 5.7%, 42.5%;在召回率方面,裂纹、未熔合、疏松类缺陷分别提升了 7.69%, 17.86%, 44.57%;在 F_1 -Score 方面,裂纹、未熔合、疏松类缺陷分别提升了 13.33%, 17.86%, 44.57%。可见所提方法可以较好地解决传统 CNN 模型在特征提取过程以及特征图映射过程中存在的问题,具有较强的复杂构件缺陷分类能力。

另外对图 7 中各类缺陷的精确度与召回率进行分析,未熔合和疏松相对于其他三类缺陷而言还有一定的差距;同时,如表 4 所示,未熔合和疏松类缺陷的数量较少,网络的学习效果偏向于气孔、夹杂等样本数据量较大的缺陷类别,从而导致未熔合和疏松类缺陷的精确度与召回率较低。

3 结论

针对传统 CNN 模型在多尺度缺陷类型识别时存在的问题,提出了一种多源特征融合深度学习模型及复杂构件缺陷类型识别方法,构建了缺陷几何先验及纹理先验特征提取模块,并提出了考虑特征重要性的 ReliefF-Pooling 方法,提高了 CNN 的缺陷类型识别能力。

通过企业实际复杂构件缺陷数据验证了该方法的有效性,同时该方法可以推广到其他制造领域(如焊缝缺陷类型识别领域),具有一定的通用性。

参考文献:

[1] 朱镇,陈晓娟,王兆云. 核电站用高磅级阀体铸件的全体积射线检测[J]. 无损检测,2022,44(1):49-52,59.

[2] 蔡彪,沈宽,付金磊,等. 基于 Mask R-CNN 的铸件 X 射线 DR 图像缺陷检测研究[J]. 仪器仪表学报,2020,41(3):61-69.

[3] JIANG H Q, WANG R X, GAO Z Y, et al. Classification of weld defects based on the analytical hierarchy process and Dempster-Shafer evidence theory[J]. Journal of Intelligent Manufacturing,2019,30(4):2013-2024.

[4] DA SILVA R R, MERY D. The state of the art of weld seam radiographic testing: part II, pattern recognition[J]. Materials Evaluation, 2007, 65 (8): 833-838.

[5] JIANG H Q, ZHAO Y L, GAO J M, et al. Weld defect classification based on texture features and principal component analysis[J]. Insight, 2016, 58: 194-200.

(下转第 22 页)




图 12 第二种齿轮倒角造成的检测盲区示意

由于齿轮空心轴内壁有高度为 3 mm 的倒角结构,会引起超声信号传输耦合不良和波束紊乱,造成工件近表面处出现约 2.5 mm 的超声未覆盖区(见图 12)。为此向焊接齿轮设计制造部门特别强调:需要进行脉冲反射法超声或相控阵超声检测的焊接齿轮,其空心轴内壁不能采用倒角结构。

表 2 第二种齿轮焊缝检测数据评定结果

缺陷编号	周向位置/(°)	深度/mm	缺陷种类	缺陷尺寸
①	27	2.6	气孔	小于 ϕ 0.5 mm
②	131	2.7	气孔	小于 ϕ 0.5 mm
③	143	3.5	气孔	小于 ϕ 0.5 mm
④	205	3.5	气孔	ϕ 0.5 mm

3 结语

(1) 利用相控阵超声技术检测齿轮焊缝是可行

的,在数据采集速度、气孔检出灵敏度、熔深线完整显示、熔深不足数据的高精度测量以及图像分辨率、记录、存储、显示功能等各个方面,相控阵超声均显示出优良的特性。

(2) 此次试验未在试件中制作裂纹缺陷,所以试验无法提供裂纹的相控阵技术检出数据。但是近十年来有专家学者对相控阵超声与脉冲反射法超声技术的裂纹检出率进行过大量对比研究,结果表明,相控阵超声技术的裂纹检出能力优于脉冲反射技术。

(3) 在汽车齿轮焊缝检测中推广应用相控阵超声技术能显著提高检测效率和可靠性,进而提高齿轮焊接质量,降低变速器失效概率和汽车故障率。

参考文献:

[1] 岑韩,覃伟钦. 变速器齿轮焊接失效分析[J]. 装备制造技术,2015(3):56-57,66.
[2] 陈兵华. 激光焊接在汽车变速器齿轮中的应用和发展前景[J]. 金属加工(热加工),2015(4):45-46.
[3] 楼敏珠. 齿轮环焊缝超声检测系统的研制与应用[J]. 无损检测,2010,32(9):730-733,740.
[4] 涂春磊,邹建华,强天鹏,等. 对接焊缝相控阵超声检测可靠性的 CIVA 仿真与试验[J]. 无损检测,2013,35(11):22-26.



(上接第 17 页)

[6] MEKHALFA F, NACEREDDINE N. Multiclass classification of weld defects in radiographic images based on support vector machines[C]//2014 Tenth International Conference on Signal-Image Technology and Internet-Based Systems. Marrakech, Morocco: IEEE,2015:1-6.
[7] YANG L,JIANG H Q. Weld defect classification in radiographic images using unified deep neural network with multi-level features [J]. Journal of Intelligent Manufacturing,2021,32(2):459-469.
[8] 姜洪权,贺帅,高建民,等. 一种改进卷积神经网络模型的焊缝缺陷识别方法[J]. 机械工程学报,2020,56(8):235-242.
[9] 雷铮强,王维斌,李立军. 中俄东线管道射线检测底片图像的智能识别[J]. 无损检测,2022,44(4):73-78.

[10] LU Q Y, WONG C H. Additive manufacturing process monitoring and control by non-destructive testing techniques: challenges and in-process monitoring[J]. Virtual and Physical Prototyping, 2018,13(2):39-48.
[11] AOUAT S, AIT-HAMMI I, HAMOUCHENE I. A new approach for texture segmentation based on the Gray Level Co-occurrence Matrix [J]. Multimedia Tools and Applications,2021,80(16):24027-24052.
[12] CARLOS E, BERTHA G, AMPARO A, et al. Scalable feature selection using ReliefF aided by locality-sensitive hashing[J]. International Journal of Intelligent Systems,2021,36(11):6161-6179.
[13] 许振浩,马文,林鹏,等. 基于岩石图像迁移学习的岩性智能识别[J]. 应用基础与工程科学学报,2021,29(5):1075-1092.