

DOI:10.16136/j.joel.2022.01.0244

基于 AW-Net 的轮毂射线图像分割算法

曹富强¹, 王明泉^{1*}, 张俊生², 邵亚璐¹

(1. 中北大学 信息与通信工程学院, 山西 太原 030051; 2. 太原工业学院 电子工程系, 山西 太原 030051)

摘要:针对传统方法下的汽车轮毂内部缺陷检测效率低、精度达不到工业标准的问题,本文提出了一种基于改进 U-Net 神经网络的轮毂 X 射线图像缺陷分割方法 AW-Net。该方法通过三级跳跃连接的方式级联两个 U 型网络对图像特征进行深度提取。同时在跳跃连接的过程中融合注意力机制以解决小目标的变化情况容易被漏检的问题,并通过实验验证结合使用多种激活函数来实现更精准的轮毂 X 射线图像语义分割,增加网络的拟合能力,提高网络的鲁棒性。实验结果表明:改进后的算法在本文构建数据集的汽车轮毂内部缺陷的误判率为 2.73%,漏判率为 0,识别率达到 93% 以上,其分割精度高于传统图像分割网络全卷积网络 (fully convolutional network, FCN) 和 U-Net,且本方法边缘分割更加平坦,满足现代轮毂内部缺陷无损检测的需要。

关键词:轮毂射线图像; 缺陷识别; 深度学习; 图像分割; U-Net

中图分类号: TP391.41 **文献标识码:** A **文章编号:** 1005-0086(2022)01-0045-08

Segmentation algorithm of wheel ray image based on AW-Net

CAO Fuqiang¹, WANG Mingquan^{1*}, ZHANG Junsheng², SHAO Yalu¹

(1. Department of Information and Communication Engineering, North University of China, Taiyuan, Shanxi 030051, China; 2. Department of Electronic Engineering, Taiyuan Institute of Technology, Taiyuan, Shanxi 030051, China)

Abstract: Aiming at the problems of low efficiency and accuracy in detecting internal defects of automobile wheels under traditional methods, and the accuracy is not up to industry standards, this paper proposes a method for segmentation of image defects in X-ray images of wheels based on improved U-Net neural network, AW-Net. This method cascades two U-shaped networks to extract image features in a three-level jump connection mode; at the same time, the attention mechanism is integrated in the jump connection process to solve the problem that the change of small targets is easy to be missed, and passes Experiments verify that a combination of multiple activation functions is used to achieve more accurate semantic segmentation of X-ray images of the hub, increase the fitting ability of the network, and improve the robustness of the network. The experimental results show that the improved algorithm has a false detection rate of 2.73%, a leakage rate of 0 and a recognition rate of more than 93% for the internal defects of automotive wheels in the data set constructed in this paper, and its segmentation accuracy is higher than that of traditional image segmentation networks, such as fully convolutional network (FCN) and U-Net, and the edge segmentation of this method is flatter and meets the needs of non-destructive detection of internal defects of modern wheels.

Key words: wheel ray image; defect identification; deep learning; image segmentation; U-Net

1 引言

轮毂是现代汽车重要的组成部件之一,其在

铸造过程中可能存在气孔、裂纹等缺陷,其质量的好坏严重影响车辆的性能和汽车行驶安全^[1]。因此对未出厂的轮毂进行缺陷的无损检测已经成为

* E-mail: wangmq@nuc.edu.cn

收稿日期:2021-04-15 修订日期:2021-05-13

基金项目:山西省重点研发计划(201803D121069)、山西省高等学校科技创新项目(2020L0624)和山西省信息探测与处理重点实验室基金(ISPT2020-5)资助项目

现代轮毂生产线的首要工序,只有顺利通过检测的轮毂,才能进行后续的机加工处理,确保产品质量合格后才能出厂。

最早的轮毂缺陷检测工作是由人裸眼检查来完成的,由于长期高强度的工作,会导致人眼的视觉疲劳,所以漏检率会比较高,再加上人眼的识别有限,有些很小的缺陷人眼是无法识别的,但这些很小的缺陷有时对铸件却是致命的^[2]。因此,探寻一种能够代替人眼的轮毂检测技术在工业界被迫切需要。

随着工业检测的发展,诞生了一批传统的检测方法,主要有渗透检测技术、磁粉检测技术、图像检测技术^[3]、连续小波转换技术、激光位移技术^[4]、光电检测^[5]及动态超声检测技术等^[6]。这些方法技术虽然相比传统的人眼检测确实有了大幅的提升,但依旧留存检测工艺复杂、精度低、效率低等问题,随后学术界的学者们相继对该课题展开了研究。STRECKER^[7]对X射线自动探伤进行了研究,使用扇形X射线和针孔相机对小型铝铸件逐层散射成像,能够检测出物体内部存在的气孔和裂纹等缺陷,但存在效率低下的问题。KEHOE等^[8]提出了一种基于层次结构的缺陷检测知识表示方法,并介绍了一种用于轮毂射线检测的专家系统(intelligent knowledge based system, IKB),但IKB系统依赖于足够多的专业知识和有效提取这些知识的方法,容易出现效率低下的问题。SERGIO等^[9]比较了欧氏距离、马尔科夫、支持向量机和神经网络等8种分类器,通过“与”、“或”、“相乘”、“求和”、“取最大”等7种方法进行分类器融合,在50幅实测数据上进行缺陷检测,获得了较低的误报率。伴随着深度学习与机器视觉的发展,深度学习技术已经迅速从科研领域蔓延到工业界,FERGUSON等^[10]针对卷积神经网络技术中模型训练遇到的数据管理问题,引入预测模型标记语言(predictive model markup language, PMML)来优化模型训练过程中的分类、回归和语义分割等问题。余永维等^[11]以深度学习技术中的卷积神经网络为基础,模拟人类大脑的视觉感知原理,利用径向基网络构建了射线图像缺陷智能识别系统。

缺陷自动识别算法在轮毂X射线全自动检测设备中扮演着非常重要的角色,它很大程度上决定了操作使用的便捷性和系统缺陷检测的准确率,是当下国产设备和进口机器存在差距的决定性因素^[12]。因此,本文在深度学习的基础上,提出了基于AW-Net神经网络结构的轮毂缺陷分割算法,该方法通过三级跳跃连接的方式级联两个

U型网络对图像特征进行了深度提取,并连接过程融合了注意力机制,使用多种激活函数对网络进行激活。通过设置对照组实验,利用Dice指标、误判率、漏判率等指标综合验证了本文方法能实现更精准的轮毂X射线图像语义分割。

2.1 图像采集与降噪

汽车轮毂的X射线图像在工厂通过工业机采集时会受到周围噪声的影响,因此直接采集到的射线图像存在噪声,且图像边缘较模糊,这会在很大程度上影响轮毂缺陷的分割。直接使用采集的图像建立训练数据库会给后续的分割工作带来更大的困难,且轮毂射线图像具有特殊性,有些特殊部位还会存在细小的纹理特征^[13]。因此要对采集到的轮毂射线图像进行滤波处理,有效去除噪声干扰。针对图像边缘模糊的问题,采用图像锐化的方式来突出图像的边缘和纹路特征。图1为轮毂射线图像预处理前后对比。

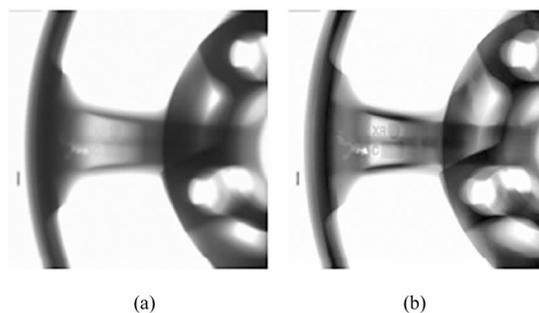


图1 轮毂射线图像预处理前后对比:

(a) 原图; (b) 预处理后结果图

Fig. 1 Comparison of images before and after preprocessing:

(a) Original image; (b) Result figure after preprocessing

2.2 图像标注和数据增强

在获取到经过上述降噪方式处理过的轮毂射线图像后,开始建立训练数据库。在使用神经网络进行训练时,需要输入缺陷标记图^[14]。本文方法使用Labelme^[15]标记缺陷部位,如图2所示。被标记区域即为轮毂缺陷部位,被记为感兴趣区域(region of interest, ROI),Labelme会将标记图生成对应json文件,存储缺陷点区域的位置和大小,通过程序可以将该文件转换为神经网络可以读取的图像文件格式,完成数据集的制作。

由于工业生产的大部分轮毂都是符合标准的,带缺陷的轮毂图像占比较低,已标注的轮毂缺陷图像数据样本较少,使用少量的数据集训练会使网络

较早过拟合,不利于网络参数的拟合。因此需要图像进行数据扩充。数据增强操作包括同时随机旋转原始图像和相应的标签、同时镜像原始图像和相应的标签、同时模糊原始图像和相应的标签及向原始图像和相应的标签添加噪声等。在这些数据扩充操

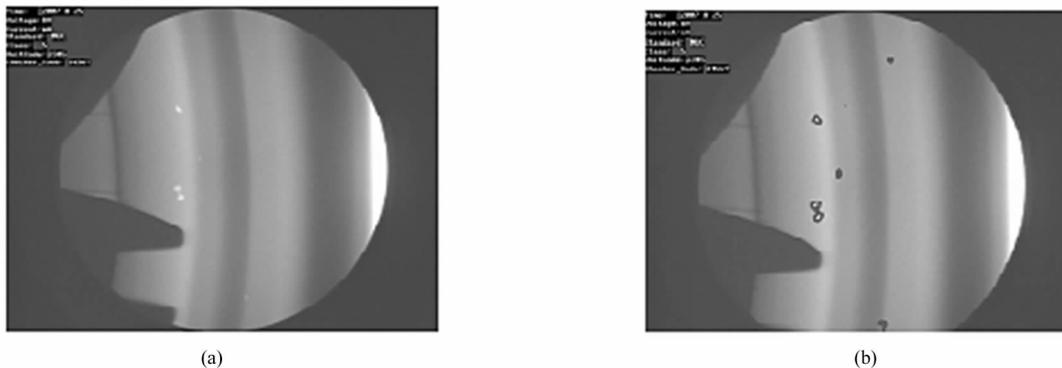


图 2 使用 Labelme 标记缺陷部位:(a) 未标记图像;(b) 标记后可视化图像

Fig. 2 Use Labelme to mark defects:(a) Untagged image;(b) Visualize the image after marking

3 AW-Net 分割模型

3.1 U-Net 网络模型

U-Net 模型是 RONNEBERGER 等^[16]提出的一种基于 FCN 的改进和延伸,因其结构形似字母 U 而得名。U-Net 架构是一种端到端的经典图像分割模型,图像输入该网络后,首先经过卷积和池化操作,进行编码,不断提取特征,卷积层特征图的大小可以通过下面的公式计算得出。

$$S_o = \frac{(S_i + 2 \times pad - K)}{S_d} + 1, \quad (1)$$

式中, S_o 和 S_i 为输出图像与输入图像的尺寸, pad 为边缘扩展像素的个数, K 为卷积核的尺寸, S_d 为卷积滑动步长。

U-Net 左边的收缩网络主要从高维度空间提取特征信息,负责下采样过程。下采样过程主要由 3×3 的两个卷积层(convolutional layer, Cony)和 2×2 的池化层组成,以 ReLU 函数为激活函数。上卷积部分旨在更准确地定位出感兴趣部位。通过反卷积操作完成上采样,每个输出特征图与左边收缩网络的每个下采样对应的特征图进行级联,以填充缺失的边界信息。网络最后,使用 1×1 卷积层并利用 Sigmoid 函数将得到的特征图映射到对应的类别。使得最终输出图像中的每个像素的值都映射在 0 到 1 范围内。将该图像作为网络的最终输出,其中每一个像素的对应值代表着该点属于缺陷的概率^[17]。

作之后,得到了大量的训练样本以增强模型的泛化能力,最终得到 2000 张缺陷图像进行训练。数据集中训练集、验证集、测试集的占比分别为 0.6、0.2、0.2,然后构建(fully convolutional network, FCN)、U-Net 和 AW-Net 神经网络。

3.2 Attention 机制

由于人类大脑在捕捉信息时是有侧重的,并不会同时关注眼前呈现的所有事物。针对这种人类大脑独特的思考方式,研究人员提出了注意力(Attention)机制。这种机制可以帮助网络从大量数据中过滤出有用信息,它在图像分类、语义分割和自然语言处理等领域受到广泛关注^[18]。Attention 机制起初被广泛应用于自然语言处理(natural language processing, NLP)领域,用于文本信息的筛选。随后,研究人员发现 Attention 机制还能在图像处理模型中带来准确率的提高,所以科研人员开始将其应用于 CV 领域。通过网络的训练可以给感兴趣的区域配置较高的权重,给其他区域配置较低的权重。当下注意力机制被使用在 3 个方面,分别是通道注意力、空间注意力及自注意力(self-attention)^[19,20],其中通道注意力机制目前被广泛使用。

注意力机制的权重分配如图 3 所示。输入为特征图 \mathbf{X} ,当经过卷积变换后得到特征信号 \mathbf{U} ,其维度为 $\mathbf{R}^{H \times W \times C}$, H 、 W 和 C 分别表示特征图的高、宽和通道数。首先经过扁平操作,沿着空间维度($\mathbf{R}^{H \times W}$)通过全局平均池化(F_{sq})来对其进行压缩,生成一个 $\mathbf{R}^{1 \times 1 \times C}$ 维度的向量:

$$z_c = F_{sq}(u_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j), \quad (2)$$

再将 z_c 通过激励,即可得到:

$$s = F_{ex}(z, W) = \sigma(g(z, W)) =$$

$$\sigma(W_2 \delta(W_1, z)), \quad (3)$$

式中, δ 代表 ReLU 激活函数, W_1 和 W_2 代表训练权重, 这样就生成了一个 $\mathbf{R}^{1 \times 1 \times C}$ 维度的向量, 然后将其和输入 \mathbf{X} 进行逐通道相乘得到 $\tilde{\mathbf{X}}_c$, 从而增强对关键

通道域的注意力。

如图 3 所示, 经过关键通道域的注意力增强后的特征图不同通道被赋予了不同的权重, 重要的通道被赋予了较大的权值。

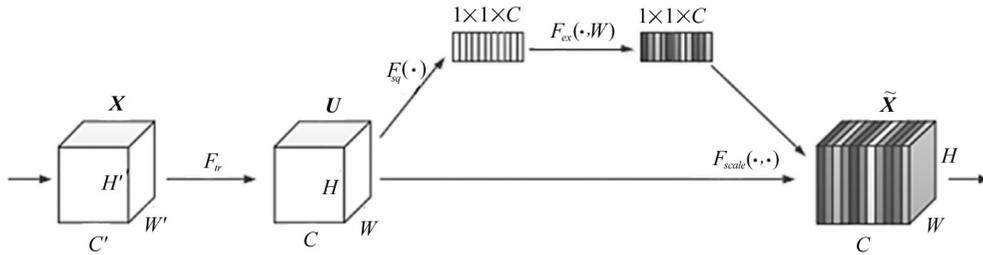


图 3 注意力机制的权重分配

Fig. 3 Weight distribution of attention mechanism

3.3 AW-Net 网络模型

受 U-Net 级联思想的启发, 本文提出了 AW-Net 神经网络模型来实现轮毂缺陷射线图像的语义分割。AW-Net 是经过两次收缩和两次扩展的端到端的卷积神经网络架构。其中每个下采样模块都由两个 3×3 的卷积核组成的卷积层和步长为 2 的池化层构成, 其中卷积可以提取特征、降低模型的复杂程度, 池化可以增大感受野。在每个下采样操作中, 卷积层的个数呈指数递增。解码过程中的每个步骤首先使用将特征通道的数量减半的反卷积, 由于下采样的过程中会造成信息损失, 尤其是一些低层特征, 需要拼接一些低层特征来还原低层信息, 从而提高分割精度。所以将反卷积的结果与相应收缩路径中的相应解码层进行特征连接。网络在跳跃连接的过程中引入了注意力机制, 使第一次下采样过程中的解码层通过该模块, 并将结果与第二次上采样的结果进行跳跃连接。

AW-Net 通过使用第一个 U 网找到粗略特征并使用第二个 U 网获得精细结果来提高网络性能。为了克服连续堆叠网络导致网络参数成倍增加的问题, 决定使用网络桥接的方法来连接前后两个网络。两个 U 网可以在多层次上充分利用不同的特征, 这将加速神经网络的收敛。实验证明, 桥接两个 U 网可以降低训练成本, 使网络适合训练数据通常不足的应用。

U-Net 模型使用 ReLU 函数进行激活, ReLU 函数的数学表达式为:

$$ReLU(x) = \begin{cases} 0, & x \leq 0 \\ x, & x > 0. \end{cases} \quad (4)$$

在输入 x 为负数时, 输出为 0, 这时表现为神经元被抑制, 不会被激活。这意味着同一时间只有部分神经元会被激活, 从而使得网络很稀疏。因此 ReLU 具有单侧抑制特性, 能给网络带来稀疏特性, 使网络快速收敛。

虽然 ReLU 函数为网络增加了稀疏性, 但是在进行计算梯度时有太多的输入值均为负值, ReLU 函数的梯度就会变为 0, 对应神经元的输出也会是 0, 可能会出现神经元死亡问题。尤其是在网络初始化的过程中, 输入值在乘以随机分配的权值后, 极有可能成为负值, 如果在此时就全部抑制, 将会使网络的性能大打折扣。

为了使网络性能更好, 网络中应用了不同的激活功能。这些激活函数可以增加权重的非线性, 使网络能够解决更繁杂的工作。由于 ReLU 在负轴上饱和, 大的学习率会“杀死”一些神经元。为了解决这一效率问题, 决定在下采样时使用 LeakyReLU 激活函数来进行激活。LeakyReLU 函数的数学表达式为:

$$LeakyReLU(x) = \max(0, x) + leak * \min(0, x). \quad (5)$$

激活函数对比如图 4 所示。当 $x < 0$ 时, LeakyReLU 函数并非立即饱和, 而是提供了一个很小的非线性偏置。

然而, 经过实验能够发现, 当网络变得更深时, 饱和仍然会发生。如果将所有的卷积块都使用 LeakyReLU 函数激活也并不会达到预期的效果, 因为当 LeakyReLU 变得饱和时, 它与 ReLU 没有什么不同。因此, 决定在下采样的过程中后期用 ReLU

替换一些 LeakyReLU 层。因为当负轴为 0 时, LeakyReLU 不饱和, 替换可以被视为“重置” LeakyReLU, 这将重新激活随后的饱和 LeakyReLU 神经元。AW-Net 网络结构如图 5 所示。下采样阶段的前三层为 LeakyReLU 模块(3 个 Conv-BN-

LeakyReLU 区块), 下采样阶段的后二层为 ReLU 模块(2 个 Cov-BN-LeakyReLU 区块)。

在网络的跳跃连接中融合了注意力机制, 使第一次下采样过程中的解码层通过注意力模块, 并将结果与第二阶段网络进行跳跃连接, 以提高模型的

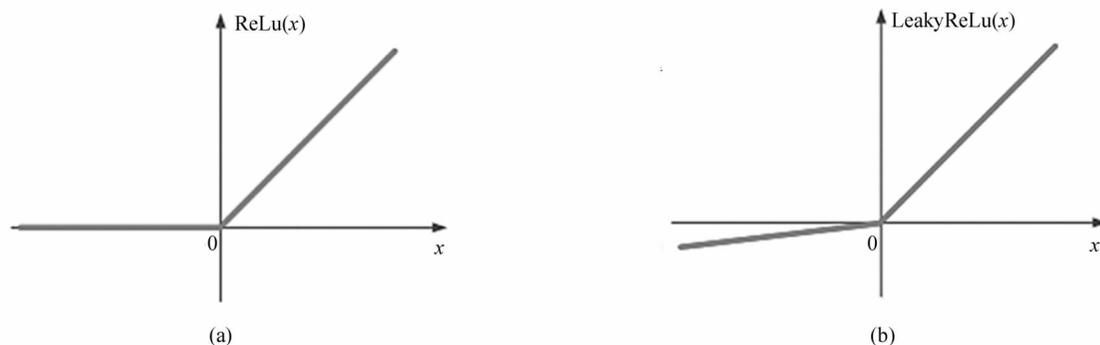


图 4 激活函数对比: (a) ReLU 函数; (b) LeakyReLU 函数

Fig. 4 Comparison of two activation functions: (a) ReLU function; (b) LeakyReLU function

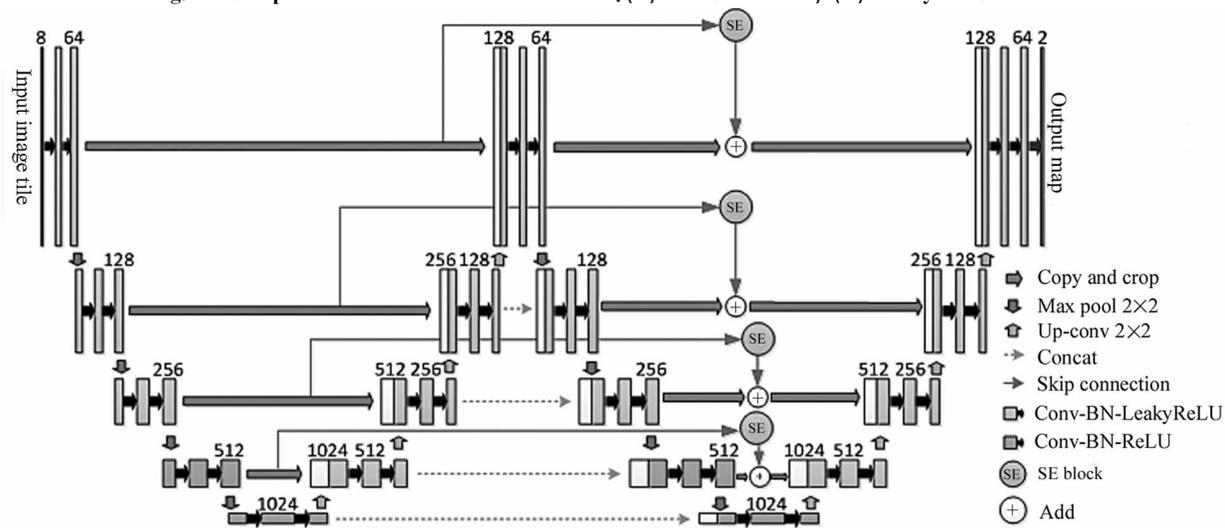


图 5 AW-Net 网络结构

Fig. 5 AW-Net network structure

分割精度。

4 试验结果分析

采用 Tensorflow 框架构建基于 AW-Net 的轮毂缺陷分割模型, 在轮毂生产工厂是用工业相机采集轮毂数据。获得的轮毂缺陷图像大小为 572×572 。计算机处理器为 Intel 酷睿 i7-9900K, 显卡为 GTX2080Ti。数据集中训练集、验证集、测试集的占比分别为 0.6、0.2、0.2, 对 AW-Net 模型和其他两种网络模型进行训练。进行数据扩充之后, 得到 2 000 张原始训练图像数据, 将这些数据作为训练样本进行网络训练。同时, 利用测试样本的缺陷部分构造

测试样本, 测试算法的分割精度。

4.1 评价指标

为了定量评价估计方法的分割性能, 采用 Dice 系数作为衡量指标。Dice 相似系数 (DSC) 产生训练损失计算如下:

$$DSC(GS, SEG) = \frac{2 |GS \cap SEG|}{|GS| + |SEG|}, \quad (6)$$

式中, GS 表示缺陷区域的黄金分割标准, SEG 表示模型的输出分割, $|GS \cup SEG|$ 表示重叠区域。 $|\cdot|$ 表示矩阵条目的总和。Dice 的损失定义为:

$$L_{Dice} = 1 - DSC. \quad (7)$$

4.2 结果对比

本文在训练集、验证集和测试集保持不变的情况下,采用 FCN、U-Net 和 AW-Net 进行控制实验。随着迭代次数增加,本文算法的精度越来越高,损失值越来越低,最终趋于稳定,网络收敛。

表 1 列出了本实验使用的 3 种模型随着训练次数递增对比数据。从表 1 可以看出,随着迭代次数的增加,实验中 3 种网络的 Dice 系数有所提高,但是 U-Net 由于网络深度的不足,在 80 次迭代之后就出现了过拟合的现象,AW-Net 的 Dice 系数还在上升,且 4 次对比中,每次 AW-Net 的 Dice 值均高于 U-Net 模型的值,体现出该网络优良的性能。

本文对 3 种不同的网络进行了对照试验,分别从分割时间、准确率、识别率、漏判率、误判率、平均 Dice 值这 6 个方面对网络模型进行综合评价。性能比较如表 2 所示。

从表 2 可以看出,改进后的网络与原网络在测试样本缺陷分割时间开销上差别不大,但是在缺陷分割准确率方面,改进后的网络较原始 U-Net 有较大的提升,由此可以看出,改进后的网络在轮毂缺陷分割上表现良好,达到预期的改进目标。就分割准确率而言,AW-Net 优于 U-Net,FCN 最低。图 6 为不同网络模型对应的 Loss 变化曲线。

表 1 训练次数递增对比数据

Tab.1 Comparison data with the increase of iteration

Method	FCN	U-Net	AW-Net
30 iterations	0.765	0.792	0.844
50 iterations	0.793	0.845	0.878
80 iterations	0.872	0.883	0.897
1 000 iterations	0.859	0.898	0.915

表 2 性能比较

Tab.2 Performance comparison

	FCN	U-Net	AW-Net
ACC	91.33%	94.26%	95.85%
Recognition rate	94.83%	96.55%	97.68%
Misjudgment rate	5.17%	3.44%	2.32%
Missing rate	0.41%	0.22%	0.00%
Dice	0.823	0.854	0.885
Time	320 ms	340 ms	400 ms

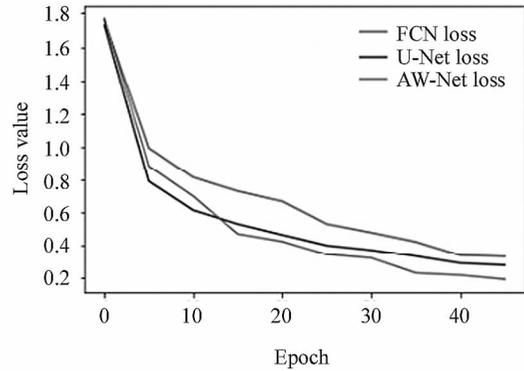


图 6 不同网络模型对应的 Loss 变化曲线

Fig.6 Loss curve corresponding to different network models

为了可视化实验结果,图 7 展示了不同神经网络模型的缺陷分割结果对比。通过对实验结果的对比分析,可以发现 FCN 的缺陷分割结果边缘不太平坦。U-Net 的轮毂语义分割结果良好,但是也有些边缘没有分割出来。通过比较,AW-Net 可以分割相对完整的轮毂缺陷,其结果是具有相对平坦的边缘。AW-Net 通过更深层次的卷积获得更低层的特征,并通过下采样和上采样输入获得的低级特征的组合可以用于细化边界信息。总体来看,在本文对

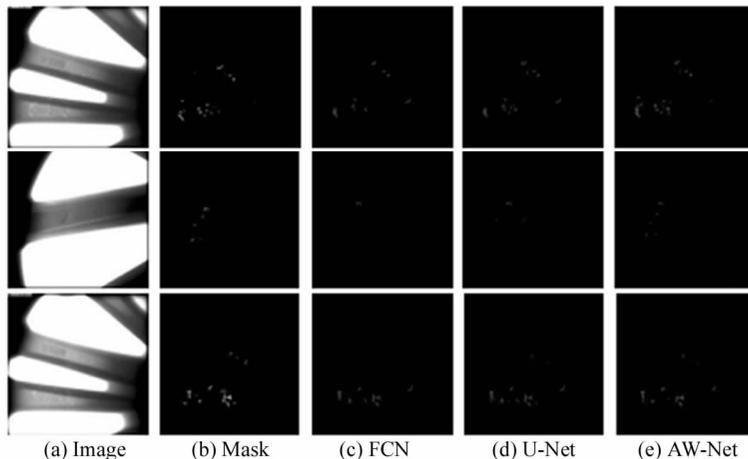


图 7 缺陷分割结果对比

Fig.7 Comparison of defect segmentation results

比的3个网络模型中,AW-Net最适合轮毂射线图像的语义分割,其次是U-Net。

5 结 论

针对轮毂射线缺陷图像分割效率低、精度低的问题,提出一种改进U-Net网络模型AW-Net,该模型使用两个U网增加了网络的深度,且对编码与解码部分进行跳跃连接,同时在该过程融合了注意力机制以增强特征信息的提取,结合使用了多种激活函数来实现更精准的轮毂X射线图像语义分割,避免了神经元被抑制的问题。并使用了3次级联在多层次上充分利用不同的特征,加速了神经网络的收敛。实验表明,该模型在轮毂图像分割上表现良好。与本实验的其他两种网络模型对比,其准确率和分割精度有很大的提升,具备潜在的应用前景。

参考文献:

- [1] WEI L, KANGSHUN L, YING H, et al. Defects of wheel hubs detection and recognition based on trend peak algorithm[J]. *Int. J. of Embedded Systems*, 2017, 9(3): 211.
- [2] WANG E Q. Research on the key technology of wheel casting defect detection[D]. Guangzhou: South China University of Technology, 2019.
王尔琪. 轮毂铸造缺陷检测的关键技术研究[D]. 广州: 华南理工大学, 2019.
- [3] WANG Q, ZHANG C. Research on defect detection technology of automobile wheel casting based on pattern recognition[J]. *Foundry Technology*, 2017, 38(12): 2889-2891.
王琦, 张超. 模式识别的汽车轮毂铸件缺陷检测技术研究[J]. *铸造技术*, 2017, 38(12): 2889-2891.
- [4] YUE J, QIU Z and CHEN B. Application of wavelet transform to defect detection of wheelflats of railway wheels [C]//The 6th International Conference on Signal Processing, August 26-30, 2002, Beijing, China. New York: IEEE, 2002: 4.
- [5] XIAO L, YU X T, YUAN X Y, et al. Research on the non-contact detection system of locomotive wheelset tread shape[J]. *Journal of Wuhan University of Technology (Information and Management Engineering Edition)*, 2010, 32(1): 85-87.
肖玲, 余先涛, 袁新宇, 等. 机车轮对踏面形貌的非接触检测系统研究[J]. *武汉理工大学学报(信息与工程版)*, 2010, 32(1): 85-87.
- [6] YIN N B, HUANG M, LIU L J, et al. MS-UNet++: retinal vessel segmentation based on improved UNet++ [J]. *Journal of Optoelectronics • Laser*, 2021, 32(1): 35-41.
- [7] STRECKER H. Scatter imaging of aluminum castings using an X-Ray fan beam and a pinhole camera[J]. *Material Evaluation*, 1982, 40(9): 1050-1056.
- [8] KEHOE A, PARKER G A. An intelligent knowledge based approach for the automated radiographic inspection of castings[J]. *NDT & E International*, 1992, 25(1): 23-36.
- [9] SERGIO H, DORIS S, DOMINGO M. Neuro-fuzzy method for automated defect detection in aluminium castings[J]. *Lecture Notes in Computer Science*, 2004, 3212: 826-833.
- [10] FERGUSON M, LEE Y T T, NARAYANAN A et al. A standardized PMML format for representing convolutional neural networks with application to defect detection[J]. *Smart and Sustainable Manufacturing Systems*, 2019, 3(1): 79-97.
- [11] YU Y W, YIN G F, YIN Y, et al. Radiographic image defect recognition method based on deep learning network[J]. *Chinese Journal of Scientific Instrument*, 2014, 35(9): 2012-2019.
余永维, 殷国富, 殷鹰, 等. 基于深度神经网络的射线图像缺陷识别方法[J]. *仪器仪表学报*, 2014, 35(9): 2012-2019.
- [12] LI D W, XIE Q, GONG X X, et al. Automatic defect detection of metro tunnel surfaces using a vision-based inspection system[J]. *Advanced Engineering Informatics*, 2021, 47: 101206.
- [13] GUO R Q, WANG M Q, ZHANG J S, et al. Automatic segmentation of automobile wheel defects based on deep learning[J]. *Science Technology and Engineering*, 2020, 20(24): 9976-9981.
郭瑞琦, 王明泉, 张俊生, 等. 基于深度学习的汽车轮毂缺陷自动分割技术[J]. *科学技术与工程*, 2020, 20(24): 9976-9981.
- [14] ZHAO H W, ZHAO Y C, QI X Y, et al. Research on surface defect detection algorithm of automobile wheel based on deep learning[J]. *Modular Machine Tool and Automatic Processing Technology*, 2019(11): 112-115.
赵海文, 赵亚川, 齐兴悦, 等. 基于深度学习的汽车轮毂表面缺陷检测算法研究[J]. *组合机床与自动化加工技术*, 2019(11): 112-115.
- [15] SAOOD A, HATEM I. COVID-19 lung CT image segmentation using deep learning methods: U-Net versus SegNet [J]. *BMC Medical Imaging*, 2021, 21(1).
- [16] RONNEBERGER O, FISCHER P, BROX T. U-Net: conv-

olutional networks for biomedical image segmentation [C]//International Conference on Medical Image Computing and Computer-Assisted Intervention, October 5-9, 2015, Munich, Germany. Berlin, Heidelberg: Springer-Verlag, 2015:234-241.

- [17] ZHOU Z, SIDDIQUEE M M R, TAJBAKHS N, et al. UNet++ : a nested U-Net architecture for medical image segmentation [EB/OL]. (2018-07-18) [2021-04-15]. <https://arxiv.org/abs/1807.10165>.
- [18] LI R, GUO M, MA M. A deep speech denoising method combining residual mechanism and attention mechanism [J]. Journal of Optoelectronics • Laser, 2021, 32 (5): 485-490.
李蕊, 郭敏, 马苗. 一种融合残差机制和注意力机制的深度语音去噪方法 [J]. 光电子 • 激光, 2021, 32 (5): 485-490.
- [19] OKTAY O, SCHLEMPER J, FOLGOC L L, et al. Attention

U-Net: learning where to look for the pancreas [EB/OL]. (2018-05-20) [2021-04-15]. <https://arxiv.org/abs/1804.03999v3>.

- [20] ZHANG G Q, LI J F. Research on recognition method of ship water gauge reading based on improved UNet network [J]. Journal of Optoelectronics • Laser, 2020, 31 (11): 1182-1196.
张钢强, 李俊峰. 基于改进 UNet 网络的船舶水尺读数识别方法研究 [J]. 光电子 • 激光, 2020, 31 (11): 1182-1196.

作者简介:

王明泉 (1970—), 男, 博士, 教授, 博士生导师, 主要从事图像处理、工业检测与识别方面的研究。