DOI:10.19651/j.cnki.emt.2416026

基于特征优化的冷凝铜管表面缺陷分割*

张雨涵[1] 陈春梅[1,2] 邓 豪[3,4] 刘桂华[1,2]
(1.西南科技大学信息工程学院 绵阳 621000; 2.特殊环境机器人技术四川省重点实验室 绵阳 621000;
3.绵阳师范学院信息工程学院 绵阳 621000; 4.四川华越汇智科技有限责任公司 绵阳 621000)

摘 要:针对冷凝铜管表面缺陷特征表达能力弱、相似缺陷之间特征混淆导致的缺陷分割精度不足的问题,提出了一种基于特征优化的冷凝铜管表面缺陷分割方法。首先,针对冷凝铜管表面缺陷显著度不足的问题,提出了一种基于缺陷区域关注度增强策略的关注度优化模块,在抑制背景特征表达的基础上提升缺陷的特征表达能力。其次,通过采用不同膨胀率的空洞卷积,并结合特征图优化技术,以实现像素跨领域语义捕获,并解决相似缺陷之间特征混淆的问题。最后,建立基于特征对齐的多尺度特征增强融合方法,提升模型对不同尺度缺陷的检测能力。在真实产线环境中拍摄的冷凝铜管图像上进行多组对比实验,结果表明,提出的研究方法在解决上述问题时取得了精度与参数量的平衡,实现了较好的分割效果。该算法平均交并比达到 80.53%、Dice 系数达到 88.94%、而模型大小仅为 25 MB。

关键词:冷凝铜管;表面缺陷;特征混淆;缺陷分割;特征优化
中图分类号:TP391.41;TN05 **文献标识码**:A **国家标准学科分类代码**:520.6040

Surface defect segmentation of condensing copper pipe based on feature optimization

Zhang Yuhan[1] Chen Chunmei[1,2] Deng Hao[3,4] Liu Guihua[1,2]
(1. School of Information Engineering, Southwest University of Science and Technology, Mianyang 621000, China;
2. Robot Technology Used for Special Environment Key Laboratory of Sichuan Province, Mianyang 621000, China;
3. School of Information Engineering, Mianyang Teachers' College, Mianyang 621000, China;
4. Sichuan HYHZ Tech. Co., Ltd., Mianyang 621000, China)

Abstract: To address the issue of insufficient accuracy in defect segmentation caused by weak expression of surface defect characteristics on condenser copper tubes and feature confusion between similar defects, a feature-optimized method for surface defect segmentation on condenser copper tubes is proposed. Firstly, to address the problem of indistinct surface defects on condenser copper pipes, the method utilizes an attention optimization module based on the defect area attention enhancement strategy to enhance the feature expression ability of defects and suppress background feature expression. Secondly, through the use of dilation convolutions with varying rates and the integration of feature map optimization technology, cross-domain semantic capture of pixels is achieved and resolve the issue of feature confusion between similar defects. Finally, a multi-scale feature enhancement fusion method based on feature alignment is established to improve the model's detection ability for defects at different scales. Multiple sets of comparative experiments are conducted on images of condenser copper tubes which are captured in real production line environments, and the results show that the proposed method achieves the balance between the precision and the number of parameters when solving the above problems, and achieves a good segmentation effect. The algorithm achieves an average intersection over union of 80.53% and a Dice coefficient of 88.94%, with the model size being only 25 MB.

Keywords: condensing copper pipe; surface defect; defect segmentation; feature confusion; feature optimization

0 引 言

铜管是空调制冷设备中的不可缺少的原材料之一,常用作冷凝器使用,与空调制冷效果有着密切联系[1]。但是,铜管在生产过程中易受到生产环境、工艺、人为因素的影响,造成缺陷[2]。这些缺陷不仅影响铜管本身的美观,而且

收稿日期:2024-05-13
* 基金项目:校博士基金(20zx7123)、中央军委装备发展部项目(23ZG8102)资助

影响空调的使用寿命，甚至危及用户的生命安全，因此空调冷凝铜管的表面缺陷检测至关重要。

铜管表面光照反应敏感，可能因光照不均匀而产生盲区，导致图像中的缺陷特征受到背景干扰而难以准确呈现。为了克服背景特征干扰对精确检测的影响，许多研究者已采用物理手段和机器学习方法来进行处理，如利用微波[3]、激光超声波[4]、高动态范围成像[5]技术进行金属表面缺陷检测，这些方法在一定程度上控制了反光和图像噪声对检测精度造成的影响。然而，不同于一般金属，冷凝铜管在制作过程中所产生的缺陷之间相似度极高，较普通缺陷更加难以区分。物理检测因工人经验不同导致结果的一致性差，，无法满足工业的生产需求[6]。传统图像处理方法在特征提取、环境适应和智能化方面不足，无法保证测量精度的稳定性[7]。基于检测的深度学习方法缺乏详细的语义信息，难以对复杂缺陷形态进行精确描述，从而无法实现更精确的缺陷检测。

经典卷积神经网络（convolutional neural networks，CNN）语义分割在工业领域的应用中具有里程碑的意义，包括最初的全卷积网络（fully convolutional networks，FCN）[8]，在医学领域普及的 Unet[9]，具有巨大潜力的 OCRnet[10]，DeepLab 系列[11-12]都在工业缺陷分割中广泛应用。

语义分割网络解决了传统金属表面缺陷检测精度不高、泛化性不强的问题，广泛应用在金属表面缺陷检测领域。王一等[13-15]对 Unet 网络进行改进，解决了光照和缺陷尺寸形状多样性导致的检测精度低的问题。范瑶瑶等[16]针对钢板表面缺陷检测中存在的边缘分割粗糙、漏检和误检率高等问题，提出了一种引入注意力机制的多征融合的 DeepLabv3＋缺陷检测方法。Sardor[17]采用基于边缘的语义分割网络提取铜管缺陷感兴趣区域。Zhang 等[18]为解决金属表面缺陷分割存在对比度低、边界信息不足等技术问题，提出多尺度关注特征融合模块，归一化均方频率类别权重策略、偏权训练采样策略和类别边界损失计算策略。尽管上述方法一定程度上解决了金属表面缺陷检测存在的问题，但在面对冷凝铜管表面缺陷特征表达不足、缺陷特征之间相似度高等挑战时仍旧存在局限。

本文从解决缺陷特征表达不明显以及相似缺陷之间特征混淆的角度研究冷凝铜管表面缺陷检测。所提算法利用 MobileNetV3[19]轻量化提取多层次特征，利用基于缺陷区域关注度增强策略的关注度优化模块（attention optimization module，AOM）、结合特征图优化技术的空洞空间卷积池化金字塔（feature map optimization atrous spatial pyramid pooling，FMO-ASPP）以及结合有效多尺度注意力机制的特征对齐融合方法（efficient multi-scale attention-feature alignment fusion method，EMA-FAFM），在解决铜管表面缺陷分割任务中的漏检、误检等问题的同时保证模型参数量的平衡。

1　冷凝铜管缺陷分割方法

受 DeeplabV3＋网络的启发，所提算法结构主要包括编码器和解码器，如图 1 所示。编码器由三部分组成，首先，通过骨干网络 MobileNetV3 轻量化提取 4 个阶段的多层次特征，其中，骨干网络阶段一提取各类缺陷轮廓特征，阶段二、三在解码器特征融合时提供多尺度信息，阶段四捕获缺陷内部语义特征。然后，为了提取更多缺陷区域特征，提出了缺陷区域关注度增强策略，即搭建坐标注意力和通道注意力双机制关注度优化模块（AOM）。最后，用特征图优化空洞空间金字塔（FMO-ASPP）对骨干深层次输出特征图进行深层次语义信息提取，运用其中的自适应空洞卷积扩大感受野，增强模型对大尺寸缺陷的感知能力，并结合特征图优化模块调整卷积层语义信息，增强相似缺陷之间的特征区分度。在解码器中，将有效多尺度注意力机制和特征对齐融合方法结合，形成 EMA-FAFM 模块，用于融合编码器输出的多尺度特征，并得到不同尺度的缺陷特征融合图。然后，通过将缺陷区域关注度增强图与多尺度语义信息融合图进行堆叠，并利用 3×3 卷积整合堆叠图的信息，形成了具备丰富缺陷特征信息的特征图。对融合特征图再次进行 3×3 卷积操作，以细化特征提取。接着，采用一个 1×1 卷积调整通道数，再运用双线性插值方法将特征图放大至原图大小，并进行类别预测实现像素级缺陷分割。

1.1　缺陷区域关注度增强策略

铜管缺陷分割任务中，背景特征表达过强，干扰网络对于缺陷区域细节的提取。为了加深缺陷区域特征信息，同时抑制背景特征表达，本文设计了一种基于坐标注意力机制及双池化通道注意力机制的缺陷区域关注度增强策略，并搭建关注度优化模块（AOM），如图 2 所示。

由主干第一阶段提取所得输出特征图作为 AOM 输入。如图 2 可知，AOM 通过双层倒残差块[20]使特征提取更加准确，网络优化更加简单，利用其中反瓶颈结构，使浅层网络能够获得丰富的特征信息。在 AOM 中，首先利用两个 1×1 卷积增加特征图，加深网络深度。其次，利用 3×3 深度可分离卷积进行轻量化特征细化。然后结合坐标注意力机制及 1×1 卷积实现缺陷区域关注度调控。并在最后利用双池化通道注意力机制及 1×1 卷积筛选有效特征，以得到缺陷区域关注度加强特征图。

坐标注意力机制（coordinate attention，CA）[21]是专为轻量级网络提出的全新注意力机制，其分别对不同空间方向进行特征图编码，得到一对方向感知与位置灵敏的注意力图。将二者互补应用输入特征图，使网络更聚焦于显著区域，如图 3 所示。

CA 首先对输入图片 X 沿宽度与高度方向分别进行一维池化，将二者堆叠后经 1×1 卷积及特征图切分操作后得到远程关系依赖图及位置信息图 α，β。

$$\alpha,\beta = F_{SPLIT}(F_{CBR}[F_{AVG_H}(X),F_{AVG_W}(X)]) \tag{1}$$

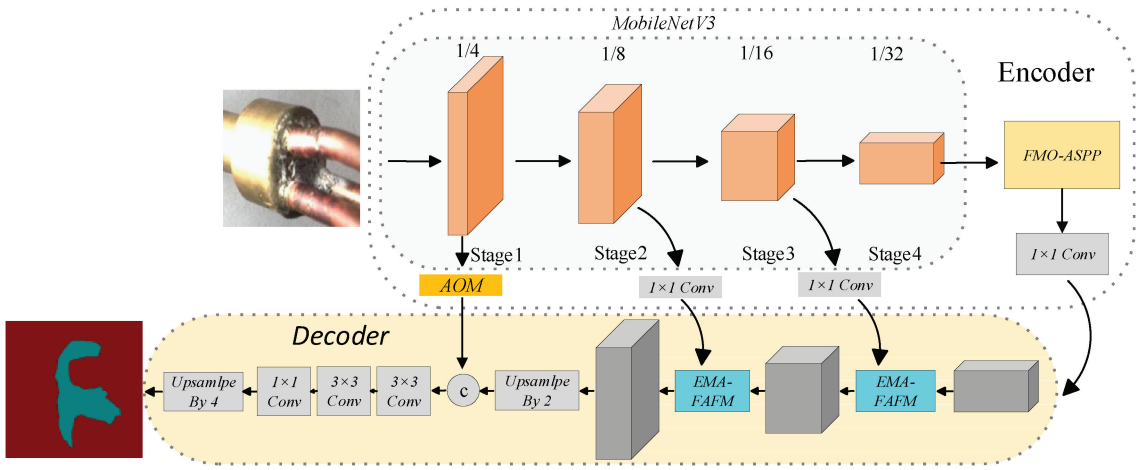

图 1 算法网络结构

Fig. 1 Algorithmic network architecture

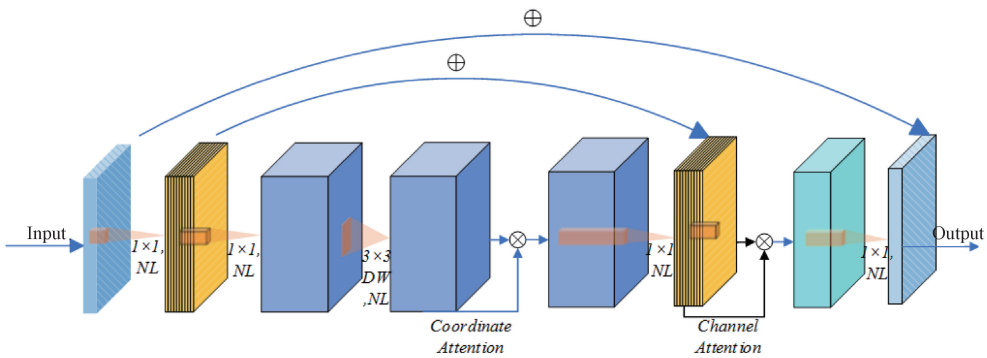

图 2 AOM 结构图

Fig. 2 Structure of AOM

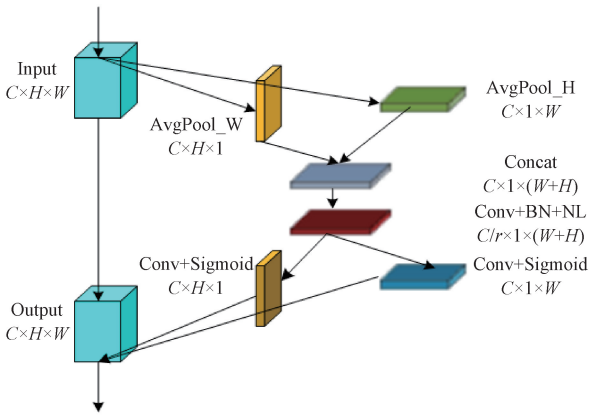

图 3 CA 结构图

Fig. 3 Structure of CA

式中:$F_{AVG_H}(\cdot)$ 分别表示沿宽度与高度方向的一维池化,$F_{CBR}(\cdot)$ 表示 1×1 卷积,$F_{SPLIT}(\cdot)$ 代表特征图切分操作。

通过将 α 和 β 进行特征细化,并将细化后特征利用归一化处理生成方向感知注意力图 σ_1 与位置敏感注意力图 σ_2。

$$\sigma_1 = F_{CS1}(\alpha) \tag{2}$$

$$\sigma_2 = F_{CS2}(\beta) \tag{3}$$

式中:$F_{CS1}(\cdot)$,$F_{CS2}(\cdot)$ 分别表示不同卷积核个数的 1×1 卷积与 Sigmoid 函数。

最后将注意力图与输入相乘得到坐标感知特征图。如下式所示,其中 Y_O 表示输出坐标感知特征图。

$$Y_O = \sigma_2 \cdot \sigma_1 \cdot X \tag{4}$$

AOM 利用双池化通道注意力机制对特征图进行重要性加权,使得解码器部分的 1×1 卷积可以通过重要性加权特征图,筛选更有效的特征得到最后的缺陷区域关注度加强特征图。双池化通道注意力机制改进通道注意力机制[22],将平均池化与最大池化结合以获取全面的特征图全局信息如图 4 所示。

其过程可以表示为:

$$Y = F_S(F_{FC}^2(F_{MAX}(X_{IN})) + F_{FC}^2(F_{AVG}(X_{IN}))) \cdot X_{IN} \tag{5}$$

式中:X_{IN} 表示输入特征图,Y 表示输出特征图,$F_{AVG}(\cdot)$ 与 $F_{MAX}(\cdot)$ 分别表示平均池化以及最大池化操作,$F_{FC}^2(\cdot)$ 代表两个全连接层,$F_S(\cdot)$ 表示 Sigmoid 函数。

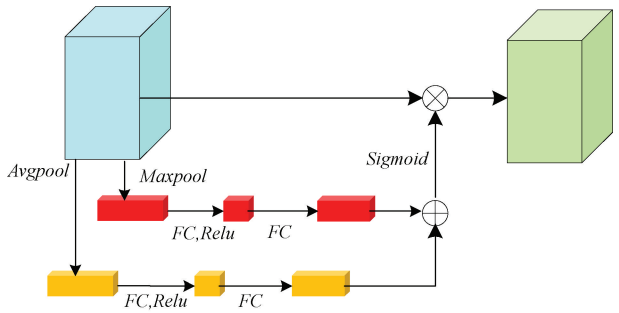

图 4　双池化通道注意力机制结构图

Fig. 4　Structure of attention mechanism of dual pool channel

1.2　语义优化金字塔

深层语义信息对于解决相似缺陷之间特征混淆至关重要。为了有效提取各种缺陷的语义特征，所提算法采用了特征金字塔多层次提取方法。其中空洞金字塔池化模块(atrous spatial pyramid pooling，ASPP)通过不同膨胀率卷积和全局池化分支捕获不同尺度的上下文和全局语义信息，有助于获取更全面的语境信息。然而，ASPP 不同操作产生了相同特征图数，特征图冗余导致不同层级的语义特征未被充分表现。

为了准确展现不同缺陷的特征细节，构建 FMO-ASPP，又称语义优化金字塔，如图 5 中所示。

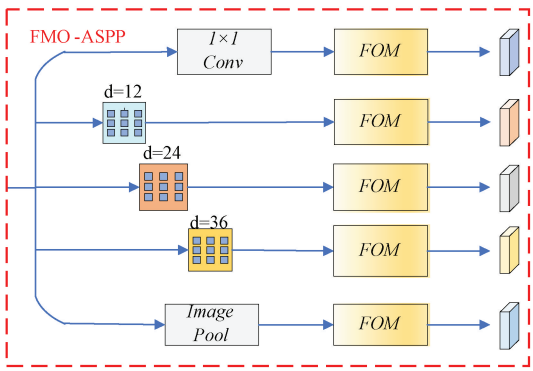

图 5　FMO-ASPP 结构图

Fig. 5　Structure of FMO-ASPP

FMO-ASPP 扩展了 ASPP 的膨胀率，使像素通过更广阔的感受野获取更丰富的特征信息，并对各层级特征图分别进行特征优化(feature optimization module，FOM)操作，捕获不同感受野下缺陷的语义特征，如图 6 所示。

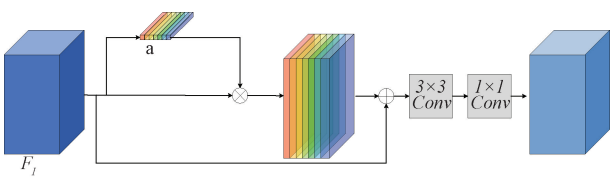

图 6　特征图优化模块结构图

Fig. 6　Structure of feature map optimization module

FOM 首先通过池化操作获取对应层级输入特征图 F_I 的全局语义信息，其次利用全局语义信息对输入特征图进行重要性建模，并输出重要性向量 α。再次，结合重要性向量 α 对输入特征图 F_I 进行加权，得到对应膨胀卷积层的加权特征图，在加权过程中，采用残差结构来保证特征提取的准确。最后，对残差后加权特征图进行特征整合，利用 3×3 卷积细化特征，1×1 卷积调整特征图数，得到优化特征图 F_O。总的来说，FOM 过程可以表述为：

$$\alpha = F_S(F_{CONV}^{1\times1}(F_{POOL}(F_I))) \tag{6}$$

$$F_O = F_{CONV}^{1\times1}(F_{CONV}^{3\times3}(F_I + \alpha \times F_I)) \tag{7}$$

式中：F_I 表示输入特征图，$F_{POOL}(\cdot)$ 表示池化操作，$F_{CONV}^{1\times1}(\cdot)$ 表示 1×1 卷积，$F_{CONV}^{3\times3}(\cdot)$ 表示 3×3 卷积，$F_S(\cdot)$ 表示 Sigmoid 函数，α 表示生成的重要性向量，F_O 表示输出特征图。

1.3　特征融合方法

特征融合方法通过多尺度信息整合，增强不同大小缺陷的语义信息，从而提高对不同尺度缺陷的区分能力。但传统特征融合方法忽视了跨模态信息之间的语义差异，造成了特征融合的信息损失。为此，提出一种结合有效多尺度注意力机制的特征对齐融合方法(EMA-FAFM)，消除融合时的特征空间不一致性，加强缺陷语义特征的表现，其结构如图 7 所示。

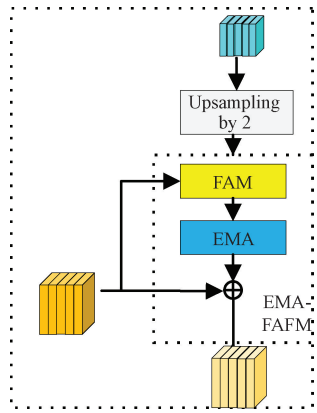

图 7　EMA-FAFM 结构图

Fig. 7　Structure of EMA-FAFM

相较于传统特征融合方法中的相加堆叠操作，EMA-FAFM 在特征结合之前采用了特征对齐模块(feature alignment module，FAM)[23] 以及有效多尺度注意力机制[24](efficient multi-scale attention，EMA)。

FAM 如图 8 所示。FAM 通过将高级特征与低级特征进行堆叠，并运用 1×1 卷积提取二者之间的关联特征，其中关联特征提供了上采样特征和对应的低级特征之间的空间差异。然后利用 3×3 卷积对关联特征进行特征细化，并将细化特征按 2∶1 比例切分得到两个空间差异调整量，将两个调整量分别作为可变形卷积 V2 (deformable convolution v2，DCNV2)[25] 中的偏移量(offset)和掩码(mask)。

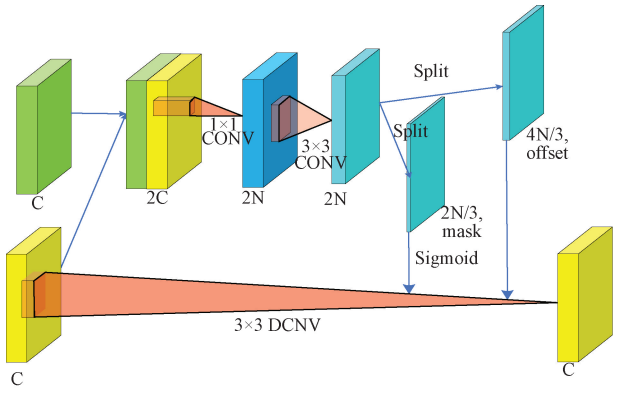

图 8 FAM 结构图

Fig. 8 Structure of FAM

DCNV2 在 DCNV1[26]的基础上添加可学习权重 Δm，用以在提取完整不规则物体表面特征的同时，区分采样点是否为感兴趣区域，如图 9(c)所示，当权重系数为零时，该采样点忽略不计。可变形卷积(DCNV2)公式如下：

$$y(p_0)=\sum_{p_n\in\Re}w(p_n)\times x(p_0+p_n+\Delta p_n)\times\Delta m_n \tag{8}$$

式中：p_0 指卷积核中心位置，p_n 指卷积核第 n 个位置，Δp_n 表示卷积核第 n 个位置的偏移量。以 3×3 卷积核为例，$R=\{(-1,-1),(-1,0),\cdots(0,1),(1,1)\}$，$p_n=(-1,-1)$ 表示卷积核左下角的位置，Δm 权重系数特指每个像素点对应的掩膜值。

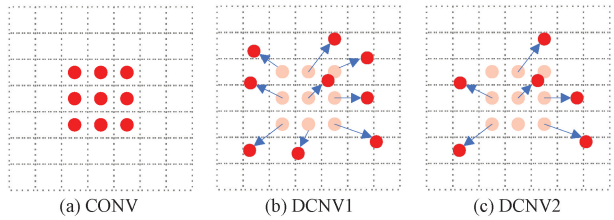

图 9 不同卷积示意图

Fig. 9 Different convolution schematics

利用含有空间差异调整量的 DCNV2 对高级特征图进行像素级位置偏移，实现与低级特征的对齐。

在高级特征与低级特征对齐之后，通过 EMA 加深对齐特征图中不同尺度的缺陷特征信息。在与低级特征融合时，这一加强使得模型能够更加有效地捕捉到对齐缺陷特征之间的关联信息，进而提升整体特征的表达质量，最终获得信息增强及丰富性提升的融合特征图。

EMA 模块结构如图 10 所示，该模块通过将特征图分组为多个子特征，以保留通道信息并减少计算成本。同时，它利用并行卷积分支(1×1 卷积和 3×3 卷积)来提取多尺度的缺陷信息和全局信息。最后，通过跨分支交互形成了像素级的注意力机制，使得特征具有富含上下文信息的特性。

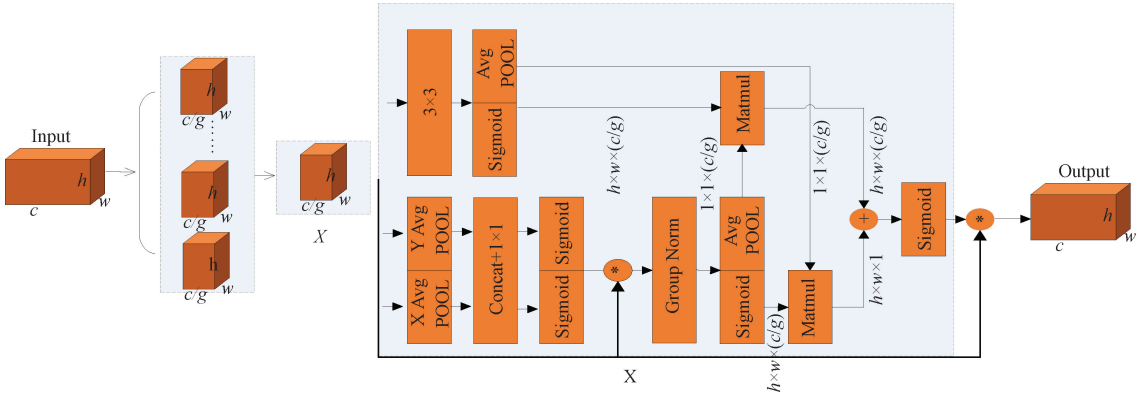

图 10 EMA 结构图

Fig. 10 Structrue of EMA

2 实验

2.1 实验设置

本文实验环境：硬件平台为 CPU(AMD 3700X 8C16T)，GPU(NVIDIA RTX2070Super 8 GB)，操作系统为 64 位 Ubuntu 18.04.5，使用 paddlepaddle2.3.2 框架构建模型，CUDA 版本为 11.1。

训练的超参数采用多项式衰减策略，设置训练时 Batchsize 为 6，训练 epoch 设为 1 300，多项式衰减策略中，初始学习率设置为 0.000 6，Power 设置为 1，End_lr 为 0。采用交叉熵损失函数 CE-Loss，采用 AdamW 作为优化器，保证其充分拟合。

2.2 实验数据集

本文使用实验数据来源于四川长新制冷部件有限公司所拍摄冷凝铜管图像，铜管数据集采集需要考虑图像采集平台的安装方式，尽可能创造理想的拍摄环境，减少外部的干扰因素。将待检测铜管放置在检测平台上，使用两个照明灯进行光照补偿，保证光照相对均匀，通过相机采集不同角度的图像，将采集到图像数据传输到计算机中保存，用于后续的标注与训练模型，数据集采集系统示意图

如图 11 所示。

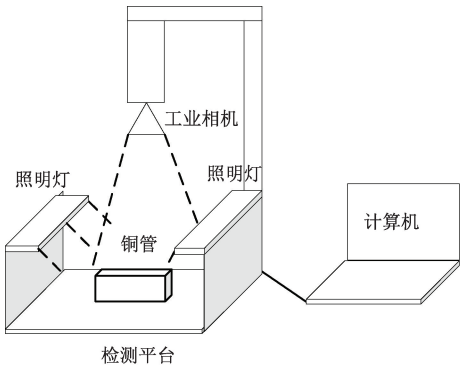

图 11　数据集采集平台

Fig. 11　Data acquisition platform

拍摄图像的空间分辨率为 3 072×2 048。由于原始图像尺寸较大，系统效率过低，故缩放大小统一至 1 024×682。使用 Labelme 为每张图像绘制六类缺陷标签：背景、黑斑、凹损、虚焊、流焊、焊接不平整，如图 12 所示。共制作 1 048 张带有标签的图像（其中包含黑斑 170 个，凹损缺陷 469 个，虚焊缺陷 135 个，流焊缺陷 726 个，边缘不平整缺陷 109 个），利用数据增强对各缺陷进行数量均衡化处理，增强后数据集扩充至 3 748 张，最后按 6∶2∶2 比例划分训练集、验证集，测试集。

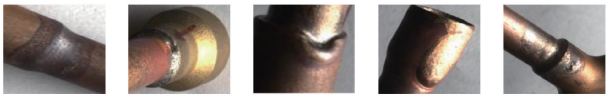

(a) 黑斑 (a) Black spot welding　(b) 虚焊 (b) Cold solder joint　(c) 凹损 (c) Dent　(d) 流焊 (d) Wave soldering　(e) 不平整 (e) Uneven welding

图 12　缺陷类型图

Fig. 12　Defect type diagram

2.3　评价指标

本文采用 5 个标准的评价指标，包括交并比（IOU），平均交并比（MIOU），DICE 系数，模型大小，浮点运算量。

IOU 是各类别的真实标签和预测值的交和并的比值。IOU 越大，对应缺陷的分割效果越好。其定义为：

$$IOU = \frac{TP}{FN + FP + TP} \tag{9}$$

MIOU 则是将全部类别 IOU 求和并除以类别个数，用于评价总体分割精度。MIOU 越大，表明总体分割效果越好。其定义为：

$$MIOU = \frac{1}{k+1}\sum_{i=0}^{k}\frac{TP}{FN + FP + TP} \tag{10}$$

DICE 系数是一种集合相似度度量函数，通常用于计算两个样本的相似度，数值越大，样本相似度越高，分割效果越好。其定义为：

$$DICE = \frac{2 \times TP}{TP + FP + TN + FN} \tag{11}$$

式中：TP 表示预测正确，一个样本被预测为正类，并且真实标签为正类；TN 表示预测正确，一个样本预测为负类，并且真实标签为负类；FN 表示预测错误，一个样本被预测为负类，但是真实标签为正类；FP 表示预测错误，一个样本被预测为正类，但是真实标签为负类；k 表示缺陷类别数。

其余指标中，模型大小表示模型存储空间，FLOPS 指模型执行时每秒浮点运算的次数，用于衡量模型计算复杂。

2.4　对比实验

为了验证所提算法的有效性，选取 DeepLabv3＋，OCRnet，Unet，FCN 进行实验对比分析。

1）定性分析

图 13 展示了各模型对单个缺陷的分割效果，缺陷依次为黑斑、凹损、流焊、焊接不平整、虚焊。可以观察到，由于缺陷特征不明显且背景特征干扰强烈，FCN 和 Unet 在所有缺陷类别上表现不佳，甚至出现误检情况。相比之下，所提算法通过缺陷特征优化和背景特征抑制等操作，在视觉效果上明显优于其他网络，缺陷边缘更加平滑。

图 14 中展示了各模型对混合缺陷的分割效果，可以看出由于所提算法利用 FMO-ASPP 优化了深层次缺陷语义特征信息，以及在解码器阶段利用 EMA-FAFM 避免了语义特征信息的损失。因此在对多个缺陷进行分割时，提高了不同相似缺陷的检测精度。

2）定量分析

将本文算法与其他先进网络模型进行对比，验证其改进的有效性。表 1 显示了在冷凝铜管验证集上不同模型的 MIOU 和 Dice 系数值，同时列出了每个模型的权重大小和 FLOPs。结果显示，本文方法在 MIOU 和 DICE 系数上均表现出较好效果，与 DeepLabv3＋、FCN、OCRnet、Unet 相比，分别提升了 2.75%、7.83%、2.51%、7.46%和 1.88%、5.51%、1.69%、5.2%。同时，参数量和计算复杂度也最低，表明在铜管缺陷分割任务中实现了精度与参数量的平衡。

表 2 中看出所提算法在所有类别分割任务中均实现了最高的 IOU，表明所提算法针对缺陷分割精度不高问题所采取的抑制背景特征表现，加强缺陷特征表达，细化边缘特征提取的操作取得成功。

3）消融实验

（1）各模块性能比较

为验证 AOM、FMO-ASPP 和 EMA-FAFM 的有效性，以本文完整的网络为基准模型，在铜管数据集上进行了 4 组消融实验。如表 3 所示，替换 FMO-ASPP 为 ASPP 导致 MIOU 下降了 0.15%，DICE 系数下降了 0.09%；不采用 EMA-FAFM 而是使用普通的相加操作导致 MIOU 和 DICE 系数分别下降了 1.39%和 0.93%；不采用关注度优化模块（AOM）导致 MIOU 下降了 0.36%，DICE 系数

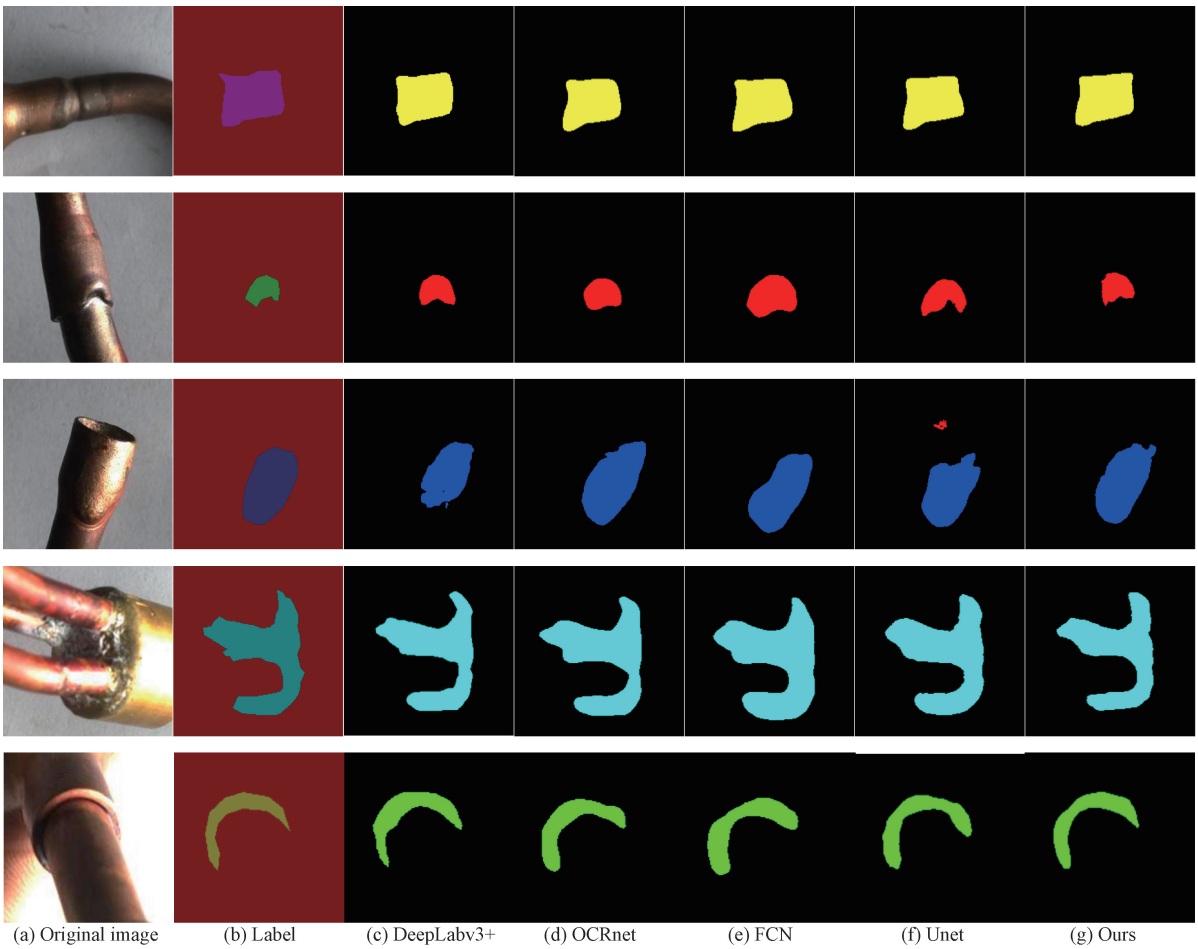

图 13 单类别缺陷分割结果比较

Fig. 13 Comparison of results of single-class defect segmentation

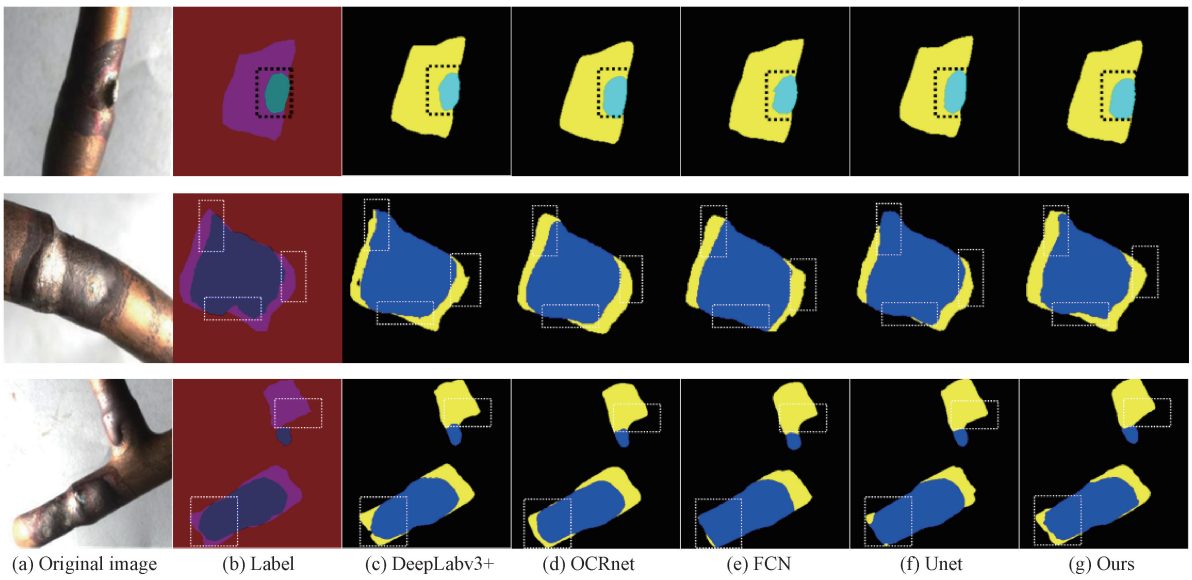

图 14 混合类别缺陷分割结果比较

Fig. 14 Comparison of mixed classification defect segmentation results

表 1　模型性能对比

Table 1　Model performance comparison

模型	MIOU/%	DICE/%	模型大小/MB	FLOPS/G
Unet	71.72	82.85	52	332.161
OCRnet	76.67	86.36	47	141.875
FCN	71.35	82.54	38	49.709
DeepLabv3+	76.43	86.17	108	102.683
Ours	**79.18**	**88.05**	25	21.886

下降了 0.23%。无论去除哪一个模块，量化指标均呈下降趋势，这表明每个模块在整体算法中都扮演着不可或缺的角色，共同保证了算法的优异性能。

(2)EMA-FAFM 模块消融实验

为验证 EMA-FAFM 模块中各操作的有效性，进行模块消融实验，基准网络为本文原始模型。由表 4 可知，仅不使用 EMA，MIOU 下降了 0.78%，DICE 系数下降了 0.41%；仅不使用特征对齐操作 MIOU 下降了 1.59%，DICE 系数下降了 0.96%，在此基础上去除特征对齐操作，MIOU 下降了 1.39%，DICE 系数下降了 0.93%。由此可

表 2　6 个类别的分割准确率对比

Table 2　Comparison of segmentation accuracy of 6 categories

模型	IOU/%						MIOU/%
	背景	缺损	虚焊	流焊	黑斑	不平整	
Unet	99.73	61.52	71.09	66.81	73.62	57.53	71.72
OCRnet	99.76	65.26	76.61	74.75	76.67	66.96	76.67
FCN	99.73	58.52	66.64	71.93	74.04	56.93	71.35
DeepLabv3+	99.77	68.22	75.91	74.69	77.36	62.61	76.43
Ours	**99.79**	**69.55**	**80.00**	**76.48**	**79.04**	**70.23**	**79.18**

表 3　不同模块对比实验分析

Table 3　Comparative experimental analysis of different modules

FMO-ASPP	EMA-FAFM	AOM	MIOU/%	DICE/%
√	√	√	79.18	88.05
—	√	√	79.03	87.96
√	—	√	77.79	87.12
√	√	—	78.82	87.82

知，特征对齐操作在多尺度融合过程中起着至关重要的作用，加强了对齐缺陷特征的特征表达，使融合更加完备。在没有使用特征对齐的情况下引入注意力机制会加强偏差特征的表现，影响融合效果，导致检测精度下降。

表 4　EMA-FAFM 消融实验分析

Table 4　Analysis of EMA-FAFM ablation experiment

特征对齐	EMA	MIOU/%	DICE/%
√	√	**79.18**	**87.96**
√	—	78.40	87.55
—	√	77.59	87.00
—	—	77.79	87.12

为验证 EMA 注意力机制的有效性，在使用特征对齐的前提下，进行与 CA、(pyramid squeeze attention, PSA)[27]、(convolutional block attention module,CBAM)[28]的对比实验如表 5 所示，相对于 CA、PSA、CBAM，EMA 在 MIOU 上分别提高 1.43%、4.13%、0.28%，在 DICE 系数上分别提高 0.84%、2.74%、0.08%。由此看出，EMA 机制在该模块中的有效性，这得益于 EMA 在提取全局信息的同时，保留了不同尺度缺陷的特征信息。

表 5　不同注意力机制对比实验分析

Table 5　Comparative experimental analysis of different attention mechanisms

注意力机制	MIOU/%	DICE/%
EMA	**79.18**	**87.96**
CA	77.75	87.12
PSA	75.05	85.22
CBAM	78.90	87.88

3　结　　论

针对冷凝铜管表面缺陷分割任务中，缺陷特征表现不明显对缺陷分割带来的挑战，本文提出了一种基于特征优化的缺陷分割方法。通过缺陷区域关注度增强策略，成功抑制背景特征表现，并增强缺陷区域特征表达。同时设计特征优化空洞空间金字塔模块，有效优化缺陷深层次语义特征提取，增强相似缺陷的特征区分度。此外提出基于特征对齐的特征融合方法，充分利用各级特征，避免特征损失，提升模型对不同尺度缺陷的检测能力。实验结果显示，本文方法表现良好。但是由于数据集的图像数量较

少,模型的学习能力还存在一定局限性,数据集的规模还有进一步提高,这是下一步需要特别关注的研究方向。

参考文献

[1] 李乐奇.空调制冷铜管在使用过程中常出现的问题[J].中国金属通报,2021,(8):160-161.
LI L Q. Air conditioning refrigeration copper pipe in the process of use often appear problems[J]. China Metal Bulletin, 2021,(8): 160-161.

[2] 刘阳. ACR铜管加工工艺与质量缺陷的研究[D].沈阳:沈阳理工大学, 2017.
LIU Y. Study on the processing technology and quality defects of ACR copper tubes[D]. Shenyang: Shenyang Ligong University, 2017.

[3] 石萌,杨理践,高松巍,等.微波传播模式对增强金属表面缺陷检测能力的研究[J].仪表技术与传感器, 2022(6):109-114.
SHI M, YANG L J, GAO S W, et al. Research on microwave propagation mode to enhance detection ability of metal surface defects [J]. Instrument Technique and Sensor, 2022(6): 109-114.

[4] 李海洋,李巧霞,王召巴.针对金属表面裂纹角度的激光超声检测[J].国外电子测量技术,2018,37(2):95-99.
LI H Y, LI Q X, WANG ZH B. Laser ultrasonic testing for the angle of surface crack on metal[J]. Foreign Electronic Measurement Technology, 2018, 37(2): 95-99.

[5] FENG W, LIU H D, ZHAO D X, et al. Research on defect detection method for high-reflective-metal surface based on high dynamic range imaging[J]. Optik, 2020, 206: 164349.

[6] 李衍照,于镭,田金文.基于改进YOLOv5的金属焊缝缺陷检测[J].电子测量技术, 2022, 45(19): 70-75.
LI Y Z, YU L, TIAN J W. Metal weld defect detection based on improved YOLOv5[J]. Electronic Measurement Technology, 2022, 45(19): 70-75.

[7] 李键,李华,胡翔坤,等.基于深度学习的表面缺陷检测技术研究进展[J].计算机集成制造系统, 2024, 30(3): 774-790.
LI J, LI H, HU X K, et al. Research progress of surface defect detection technology based on deeplearning[J]. Computer Integrated Manufacturing Systems, 2024, 30(3): 774-790.

[8] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 3431-3440.

[9] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]. Medical Image Computing and Computer-assisted Intervention-MICCAI 2015: 18th International Conference, 2015: 234-241.

[10] YUAN Y H, CHEN X, WANG J D, et al. Segmentation transformer: Object-contextual representations for semantic segmentation[J]. ArXiv preprint arXiv:1909.11065, 2019.

[11] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 40(4): 834-848.

[12] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018: 801-818.

[13] 王一,龚肖杰,程佳.基于改进U-net的金属工件表面缺陷分割方法[J].激光与光电子学进展,2023, 60(15): 333-338.
WANG Y, GONG X J, CHENG J. Metal workpiece surface defect segmentation method based on improved U-net[J]. Laser & Optoelectronics Progress, 2023, 60(15): 333-338.

[14] 陈德阳,唐智,何牧耕.基于OCR-UNet的金属表面缺陷分割[J].组合机床与自动化加工技术,2023(11): 169-173.
CHEN D Y, TANG ZH, HE M G. Segmentation of metal surface defect based on OCR-UNet[J]. Modular Machine Tool & Automatic Manufacturing Technique, 2023(11):169-173.

[15] VENGALOOR R P, MURALIDHAR R. Deep learning based semantic segmentation technique for anomaly detection on mmetal surfaces using hhigh calibre U-shaped network[J]. Traitement du Signal, 2022, 39(6): 2023-2031.

[16] 范瑶瑶,王兴芬,刘亚辉.改进DeepLabv3+网络的钢板表面缺陷检测研究[J].计算机工程与应用, 2023, 59(16):150-158.
FAN Y Y, WANG X F, LIU Y H. Improved DeepLabv3+ model for surface defect detection on steel plates [J]. Computer Engineering and Applications, 2023, 59(16):150-158.

[17] SARDOR S.基于机器视觉的铜管表面缺陷自动检测[D].哈尔滨:哈尔滨工业大学,2021.
SARDOR S. Automatic detection of surface defects of

copper pipes based on machine vision[D]. Harbin: Harbin Institute of Technology, 2021.

[18] ZHANG Z, WANG W B, TIAN X Y, et al. Semantic segmentation of metal surface defects and corresponding strategies[J]. IEEE Transactions on Instrumentation and Measurement, 2023,72:1-13.

[19] HOWARD A, SANDLER M, CHU G, et al. Searching for mobilenetv3[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 1314-1324.

[20] SANDLER M, HOWARD A, ZHU M, et al. Mobilenetv2: Inverted residuals and linear bottlenecks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.

[21] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13713-13722.

[22] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.

[23] HUANG S, LU Z, CHENG R, et al. Fapn: Feature-aligned pyramid network for dense image prediction[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 864-873.

[24] OUYANG D, HE S, ZHANG G, et al. Efficient multi-scale attention module with cross-spatial learning[C]. ICASSP 2023-2023 IEEE International Conference on Acoustics, Speech and Signal Processing(ICASSP), 2023: 1-5.

[25] ZHU X, HU H, LIN S, et al. Deformable convnets v2: More deformable, better results[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 9308-9316.

[26] DAI J, QI H, XIONG Y, et al. Deformable convolutional networks[C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 764-773.

[27] ZHANG H, ZU K, LU J, et al. EPSANet: An efficient pyramid squeeze attention block on convolutional neural network[C]. Proceedings of the Asian Conference on Computer Vision, 2022: 1161-1177.

[28] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision(ECCV), 2018: 3-19.

作者简介

张雨涵,硕士研究生,主要研究方向为深度学习、缺陷检测。

E-mail:983492642@qq.com

陈春梅(通信作者),副教授、博士,主要研究方向为图像处理、物联网工程、智能软件开发。

E-mail:47920787@qq.com

邓豪,讲师、博士,主要研究方向为计算机视觉,图像处理。

E-mail:dialouch@163.com

刘桂华,教授、博士,主要研究方向为计算机视觉,图像处理,基于 FPGA 的集成电路设计。

E-mail:liughua_swit@163.com