

DOI: 10.13382/j.jemi.B2407658

UWD-Net: 一种轻量级超声波焊接表面缺陷检测网络设计*

梁峰¹ 赵伦² 王森¹

(1. 昆明理工大学机电工程学院 昆明 650500; 2. 深圳职业技术大学智能制造技术研究院 深圳 518055)

摘要: 超声波焊接技术被广泛应用于工业制造领域,但焊接参数、设备状态和操作技术等因素常导致焊接缺陷多样化。为提高焊接效率,基于深度学习提出了一种轻量级网络 UWD-Net 用于超声波焊接表面缺陷检测。首先,针对传统卷积在焊接缺陷检测中对细节信息不敏感、容易丢失关键细小缺陷特征的问题,提出了一种新型分步注意力卷积模块 SA-Conv。SA-Conv 架构增强了模型对缺陷特征的感知能力,并降低了设备运算成本。其次,针对复杂焊接缺陷特征提取困难的问题,设计了一种基于可变形卷积和 SA-Conv 的 DCN-Module 与 WDFE-Module 的缺陷特征提取网络。该网络在复杂背景下显著增强了对缺陷目标的表征能力,实现了对形状多变等特点的焊接缺陷特征的充分提取。最后实验结果定量与定性分析表明,UWD-Net 在自建焊接缺陷数据集和 NEU-DET 公开数据集上均取得了优异的检测性能。在自建焊接缺陷数据集上,UWD-Net 的 F1 值和平均精度均值(mAP)mAP@0.5 分别达到 0.952 和 93.6%,而在 NEU-DET 数据集上,其 F1 值和 mAP@0.5 分别达到 0.710 和 78.6%,均优于其他对比算法。此外,UWD-Net 的模型参数量仅为 1.818×10^6 ,帧率达到 145.80 fps,充分实现了检测精度与推理速度的平衡,为工业环境下的实时缺陷检测与部署提供了有效支持。

关键词: 超声波焊接;UWD-Net;缺陷检测;注意力机制;特征提取;缺陷特征

中图分类号: TP391.4; TN911.73

文献标识码: A

国家标准学科分类代码: 520.2040

UWD-Net: A lightweight network design for ultrasonic welding surface defect detection

Liang Feng¹ Zhao Lun² Wang Sen¹

(1. Faculty of Mechanical and Electrical Engineering, Kunming University of Science and Technology, Kunming 650500, China;

2. Institute of Intelligent Manufacturing Technology, Shenzhen Polytechnic University, Shenzhen 518055, China)

Abstract: Ultrasonic welding technology is widely utilized in industrial manufacturing, however, factors such as welding parameters, equipment conditions, and operational techniques often lead to diverse welding defects. To enhance welding efficiency, this study proposes a lightweight deep-learning-based network, ultrasonic welding defect detection network, for ultrasonic welding surface defect detection. First, to address the limitations of conventional convolutional networks, which are often insensitive to fine details and prone to losing critical small-scale defect features in welding defect detection, this study introduces a novel stepwise attention convolution module. The SA-Conv architecture enhances the model's ability to perceive defect features while reducing computational overhead. Second, to tackle the challenge of extracting complex welding defect features, this study designs a defect feature extraction network incorporating a deformable convolutional network module and a welding defect feature extraction module based on deformable convolution and SA-Conv. This network significantly improves defect representation in complex backgrounds, enabling the effective extraction of welding defect features with varying shapes and intricate characteristics. Finally, quantitative and qualitative experimental analyses demonstrate that UWD-Net achieves superior detection performance on both a self-constructed welding defect dataset and the publicly available NEU-DET dataset. On the self-constructed dataset, UWD-Net achieves an F1-score of 0.952 and a mAP@0.5 of 93.6%, while on the NEU-DET dataset, it attains an F1-score of 0.710 and a mAP@0.5 of 78.6%, outperforming other benchmark algorithms. Furthermore, UWD-Net

收稿日期: 2024-11-18 Received Date: 2024-11-18

* 基金项目: 国家自然科学基金(12104324)、高层次人才科研启动项目(6022310046K, 6024330003K)、深圳大-新栋力超声波焊接技术研发中心(602331009PQ)、深圳职业技术大学博士后出站后期项目(6023271014K1)资助

has a lightweight model size of only 1.818×10^6 parameters and achieves an FPS of 145.80, effectively balancing detection accuracy and inference speed. These characteristics make UWD-Net well-suited for real-time defect detection and deployment in industrial applications.

Keywords: ultrasonic welding; UWD-Net; defect detection; attention mechanism; feature extraction; defect features

0 引言

随着连接工艺的不断发展和创新,对焊接质量的要求变得更为严苛。传统焊接技术(如电弧焊、气焊和激光焊等)所面临的高温影响、污染和材料选择限制等问题促使了超声波焊接技术的快速发展。超声波焊接技术在现代工业中发挥着至关重要的作用。因其热影响区小且成本相对较低,超声波焊接在汽车、电子、医疗器械和航空航天工业中得到了广泛的应用。超声波焊接原理是利用超声波频率的机械振动能量连接相似金属或异种金属^[1]。在静压力下,焊接头的振动引起导线和端子之间的摩擦,产生热量使得导线与端子接触面局部融化。当振动停止时,焊接头继续施加的压力会使局部熔化的导线与端子压合。随着热量的散失,局部熔化的导线迅速冷却和凝固,并形成坚固的焊接接头。由于焊接工艺是一个复杂的过程,焊接头的质量易受焊接电流、电压、材料性质与焊接位置等焊接参数与外部因素的影响,因此导线与端子的超声波焊接中常会产生多种类型的缺陷。目前超声波焊接缺陷检测主要通过专业的检测人员进行目视检测,这种误检率高和效率低的检测方式容易受主观因素影响。因此,为了提高焊接缺陷的检测效率,利用视觉技术对超声波焊接成型质量进行实时监测是生产制造的关键一步。

大量研究表明,基于视觉的表面缺陷检测在工业应用取得了突出的表现,并被广泛应用于实际生产。通常,机器视觉的表面缺陷检测方法的过程一般分为两个步骤:特征提取和缺陷检测^[2]。对于各种特征提取器,如 Gabor 滤波器^[3]与角点检测^[4]等算法被应用于特征提取。支持向量机(support vector machine, SVM)^[5]被广泛用作分类器,其检测流程主要包括设计特征提取算法对图像进行特征提取,随后,利用分类器确定目标对象是否为缺陷。然而,这类方法通常需要手工设计目标特征,具有复杂的图像预处理和特征提取操作。特征的单一化使得模型在处理复杂缺陷图像时容易出现误检和漏检等问题。所以传统算法的准确性和鲁棒性仍然存在一定的局限性。

随着人工智能的快速发展,深度学习技术已经在图像分类、目标检测、语义分割和实例分割等视觉任务上取得优异表现。由于卷积神经网络能够从大量的数据集中学习 and 提取到高维的特征,因此深度学习技术更适用于

非线性、高维的目标识别任务中。所以,基于深度学习的工业表面缺陷检测技术已经在焊接缺陷检测中有了初步探索。Sassi 等^[6]使用深度学习网络对低分辨率相机采集的焊接图像进行缺陷检测,并通过数据增强和迁移学习方法提升了网络的泛化能力。李辉等^[7]通过采用两阶段深度网络实现了对输电线路的异常目标检测。周鑫等^[8]通过改进 YOLOv5 算法实现了高效的钢管焊接缺陷检测。Tao 等^[9]通过设计一种紧凑的卷积神经网络(convolutional neural network, CNN),实现了对金属表面缺陷进行分割。由于在 CNN 下采样过程中缺陷特征信息容易丢失^[10],所以对于一些形状多变和目标较小的缺陷很难进行精确定位。因此为了提高多尺度缺陷的检测性能,需要有效地利用各种形状和较小缺陷有用的特征信息。为了增强网络关注特征信息间的关联性,注意力机制被提出。作为一种可以模拟人类视觉系统中注意力分配的方法,注意力机制在深度学习中被广泛应用^[11]。将设计的注意力机制加入到视觉检测任务中可以显著提高检测算法对工业表面缺陷的定位^[12]。Liu 等^[13]提出了一种基于注意力机制的新型轻量级特征融合网络模型。通过细化对缺陷目标区域的关注,解决了风力发电机叶片表面缺陷检测耗时长、效果差等问题。Chen 等^[14]使用基于视觉注意力机制的 SPAM(squeeze and position attention mechanism)对管道焊缝缺陷的进行无损检测。然而,尺寸、形状和背景的差异导致一些缺陷特征被注意机制所忽略,从而导致次优的缺陷检测性能^[15]。因此,注意力机制更应被高效的应用于表面缺陷检测任务中。

基于以上问题,本文从超声波焊接线束表面缺陷检测的实际需求出发,提出了一种基于深度学习的超声波焊接表面缺陷检测算法(ultrasonic welding defect detection network, UWD-Net)。该算法具有较小的参数量和与较高的检测精度,满足了工业焊接线束表面缺陷检测的需求。

1 方法

1.1 超声波焊接缺陷检测网络设计

在实际的工业缺陷识别场景中,检测模型需要拥有较高的稳定性和高效性。由于线束焊接缺陷具有背景复杂、形状多变、位置随机和缺陷类型复杂等特点,传统的超声波焊接线束缺陷检测方式难以实现准确、快速和高

效的检测任务。因此,为了提高网络对超声波焊接线束缺陷的检测效率,提出了一种新型的网络架构名为

UWD-Net,其网络架构如图 1 所示。

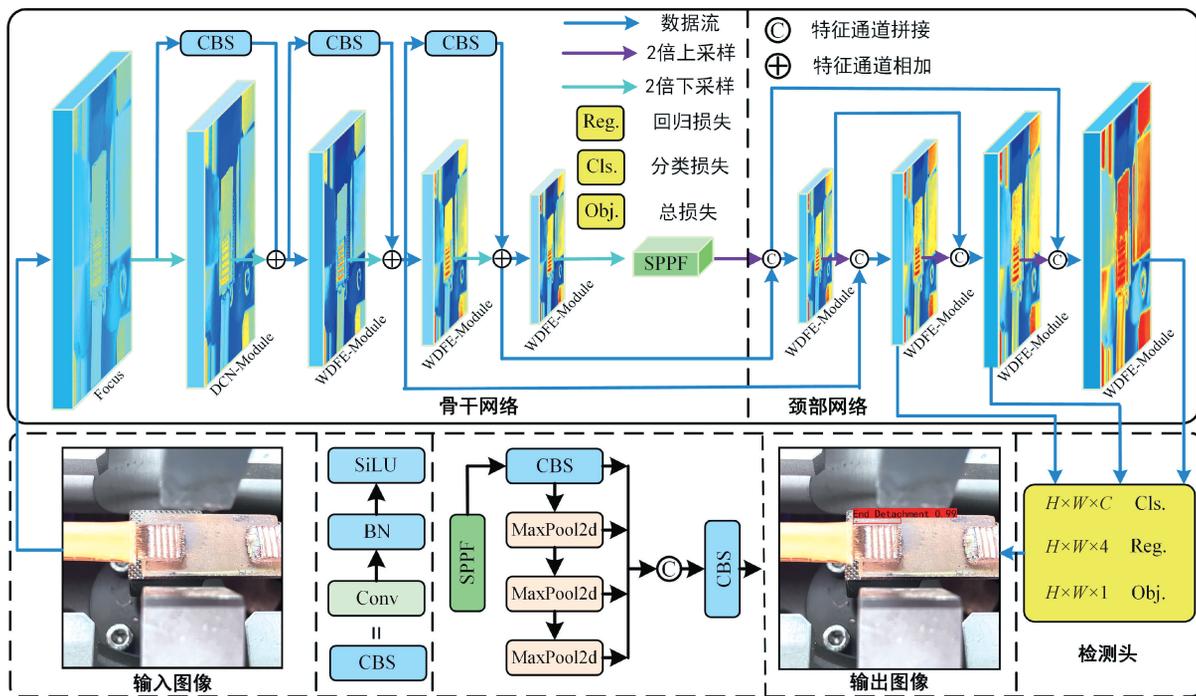


图 1 超声波焊接缺陷检测网络架构

Fig. 1 Ultrasonic welding defect detection network architecture diagram

在特征提取部分,通过构造焊接缺陷特征提取网络,并且在各个特征提取层之间采用 CBS 模块进行特征之间的交互,使得复杂焊接缺陷信息被充分提取。并且在浅层网络中采用可变形卷积网络模块 (deformable convolutional network module, DCN-Module),实现了对位置随机等缺陷特征信息的充分提取。在特征融合层,本方法使用了基于 SA-Conv (stepwise attention convolution) 的轻量级焊接缺陷特征提取模块 (welding defect feature extraction module, WDFE-Module),在节约计算资源的前提下,使得缺陷特征信息得到充分融合,最终使得模型能够精确地定位各类焊接缺陷。

1.2 分步注意力机制卷积架构

由于不同通道之间的特征具有高度的相似性,网络的部分层间的特征呈现出相似的模式。因此利用卷积神经网络对图像进行逐通道特征提取既会导致信息冗余又会增加计算成本^[16],不利于对焊接缺陷特征的提取。为了解决上述问题,提出了一种新型的分步注意力机制卷积架构 SA-Conv,如图 2 所示。

首先,将输入特征按照前 25%与后 75%通道数进行划分,如式(1)所示,其中 X_1 与 X_2 分别表示输入特征层的前 25%的通道层数与后 75%的通道层数,其中 $X \in (B, C, H, W)$, C 与 $Dim=1$ 分别表示特征层数与对通

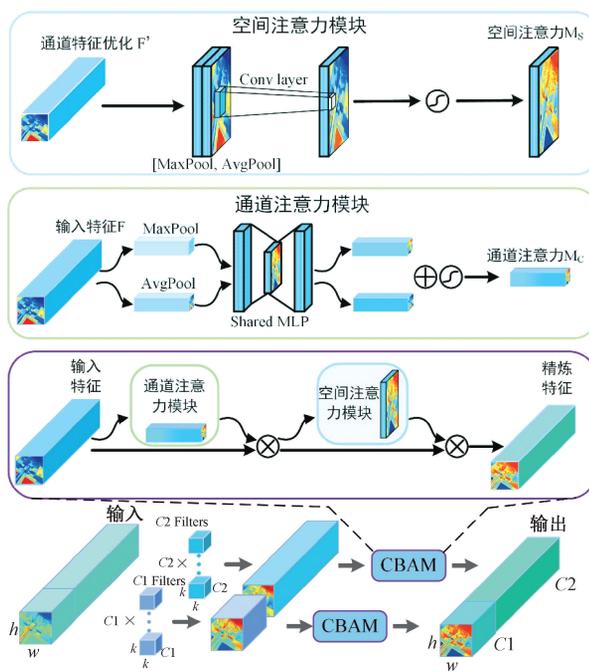


图 2 分步注意力机制卷积架构

Fig. 2 Stepwise attention mechanism convolutional architecture

道特征维度进行拆分。为了获得焊接缺陷的代表性特征信息,首先采用 3x3 普通卷积块对特征图的前 25%通道

数进行空间特征提取。对于后 75%通道层的特征图,利用点卷积层进行特征空间融合,以避免部分缺陷特征信息的丢失,如式(2)所示。其中 $Conv_{3 \times 3}$ 与 $Conv_{1 \times 1}$ 分别表示卷积核为 3×3 和 1×1 的卷积核。

$$X_1, X_2 = Split(X, [\frac{C}{4}, C - \frac{C}{4}], Dim = 1) \quad (1)$$

$$X_3 = Conv_{3 \times 3}(X_1), X_4 = Conv_{1 \times 1}(X_2) \quad (2)$$

其次,分别将代表性缺陷特征信息与部分缺陷特征信息输入到卷积块注意力模块(convolutional block attention module, CBAM)^[17],如式(3)所示。通过 CBAM 注意力机制中的空间注意力模块与通道注意力模块对网络的权重信息进行了调整。最后,将注意力机制处理后的两部分缺陷特征信息进行拼接,拼接后的缺陷特征信息具有更强的表达能力,减少了各个通道之间的缺陷特征冗余信息,如式(4)所示。其中 $Cat(\cdot)$ 表示通道拼接。通过对输入缺陷特征进行以上处理,提高了网络对各类缺陷的识别和定位精度。

$$X_5 = CBAM(X_3), X_6 = CBAM(X_4) \quad (3)$$

$$X_{output} = Cat(X_5, X_6, Dim = 1) \quad (4)$$

在 CBAM 注意力机制中,通道注意力模块分别使用最大池化和平均池化操作对缺陷特征进行空间上的信息聚合,随后对聚合后的特征信息进行过滤、激活函数和归一化处理。对于一些较小的缺陷信息(如线芯污渍、断芯),经通道注意力处理后的网络能够更好地关注并学习它们的细节缺陷信息,从而提高网络对断芯等缺陷的判别能力。空间注意力模块首先使用卷积生成用于计算注意力权重的特征映射,并通过特征映射完成对每个空间位置权重的计算。最后,使用空间位置权重对原始特征图进行加权池化,使得网络能够在特征图的不同位置上赋予不同的权重。因此在检测侧边脱落等位置随机的缺陷时,可以更有效地赋予这些区域较大的权重。这有助于模型更有针对性地关注缺陷所在的空间位置,提高对这类缺陷的检测性能。

SA-Conv 架构有助于减少计算量与提高模型对关键特征信息的感知,从而降低设备运算成本与提高网络特征提取能力。当输入输出通道数相同时,普通卷积的复杂度计算如式(5)所示。本文使用特征图的前 25%通道数进行普通卷积的复杂度计算如式(6)所示,剩余通道数进行点卷积的复杂度计算如式(7)所示,CBAM 注意力机制处理分步卷积后的复杂度计算如式(8)所示。由于 CBAM 是一个轻量级注意力模块,且与 F_1 、 F_2 和 F_3 相比不在同一数量级上,因此可以忽略 CBAM 注意力带来的计算复杂度影响。值得一提的是,当分别使用 SA-Conv 与普通卷积对相同通道特征图进行卷积操作时,浮点计算量减少到了原来的 $1/8$,如式(9)所示。

$$F_1 = K_h \times K_w \times C^2 \times H \times W \quad (5)$$

$$F_2 = K_h \times K_w \times \frac{1}{16} C^2 \times H \times W \quad (6)$$

$$F_3 = 1 \times 1 \times \frac{9}{16} C^2 \times H \times W \quad (7)$$

$$F_4 = C^2 + H \times W \times C + H \times W \quad (8)$$

$$N = \frac{F_1}{F_2 + F_3 + F_4} \quad (9)$$

式中: K_h 、 K_w 分别表示卷积核的高与宽; C 表示通道数; H 与 W 分别表示图像的高与宽。在神经网络中随着网络的叠加,采用 SAM-Conv 架构可以大大降低网络的浮点数。因此使用 SA-Conv 架构有助于减少网络参数量与复杂度,从而减轻工业场景下对计算设备算力需求。

1.3 焊接缺陷特征提取网络

由于焊接缺陷存在背景复杂、形状多变、位置随机和缺陷类型复杂等特点。这使得算法模型对缺陷信息进行完整的特征提取面临着挑战。因此,在充分考虑到缺陷类型与背景复杂等特点,提出了一种新型的焊接缺陷特征提取网络架构,网络架构如图 1 中骨干网络所示。为了适应缺陷呈现的不规则形状和位置的多变性,本文基于可变形卷积^[18]设计了一种 DCN-Module,并将其应用到浅层网络中对缺陷特征信息进行提取,其架构如图 3 所示。

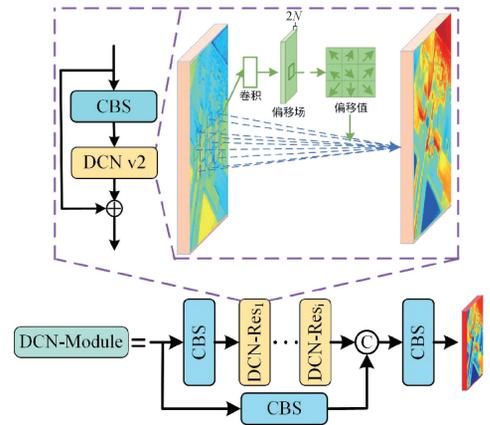


图 3 可变形卷积特征提取模块架构

Fig. 3 Architecture of deformable convolutional feature extraction module

首先,为了使得模型学习到输入特征的不同抽象级别的表示。对输入特征进行了降维,这可以帮助模型集中学习重要缺陷特征信息,而去除一些不重要的背景信息。可变形卷积通过学习参数来确认卷积核的形状和偏移,有效提高了网络对不规则缺陷(如侧边脱落和芯丝鼓起)的特征提取,如式(10)所示。其中 σ 与 BN_2 分别表示激活函数与批标准化处理; DCN_{v_2} 、 $Offset$ 与 $Mask$ 分别表示可变形卷积、偏移量与掩码。因此,通过可变形卷

积,网络能够动态地调整卷积核的形状和位置,从而更好地适应缺陷的形状和位置变化。为了加速网络模型的收敛,本文方法采用了残差模块,用于融合输入特征和可变形卷积处理后的特征。这样做充分利用了多层次、多尺度的特征信息,使得网络在训练过程中更迅速地学习到有效的缺陷特征表示,具备更强的表征能力。最后通过可变形卷积残差结构(DCN-Res)和CBS模块构成了DCN-Module,实现了对形状多变和位置随机的焊接缺陷的充分提取。

$$X = \delta(BN_2(DCN_{i_2}(x, Offset, Mask))) \quad (10)$$

由于降采样过程会引起缺陷细节信息的丢失,从而导致部分焊接缺陷特征逐渐模糊。因此本文方法基于分步注意力机制卷积模块构造了一种轻量级焊接缺陷特征提取模块WDFE-Module来解决特征信息丢失等问题,并将此架构用在网络中对缺陷特征进行提取与融合,其网络架构如图4所示。

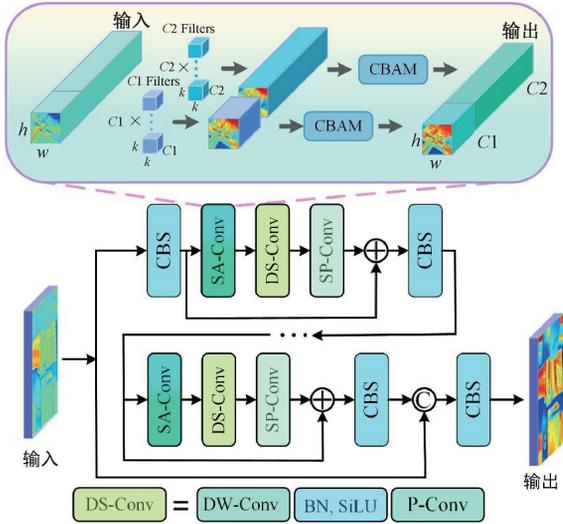


图4 轻量级焊接缺陷特征提取架构

Fig. 4 Lightweight welding defect feature extraction module

为了便于后续不同通道的信息融合,首先对输入特征进行降维,如式(11)所示,其中 c 表示通道数, $Dim = 1$ 表示通道维度。为了增强网络对细节缺陷特征信息的感知能力,采用了SA-Conv进行特征提取与融合,如式(12)所示。SA-Conv卷积有效防止了细节缺陷特征信息的丢失,避免了部分缺陷特征在深层网络中的模糊,并且降低了模型参数数量。深度卷积(DW-Conv)和点卷积(P-Conv)^[19]的结合能够有效提取不同通道上的缺陷特征并实现通道间的信息交互。因此,将DW-Conv与P-Conv加入到WDFE-Module以获得更丰富的缺陷特征。此外,为了赋予网络具有更好的稳定性与收敛性,对提取到的缺陷特征进行BatchNorm与SiLU处理,如式(13)所示,其中 BN_2 与 $SiLU$ 分别表示批量归一化与激活函数。采

用SP-Conv(split convolution)^[20]进一步对缺陷特征进行提取。其中,重要的缺陷特征可以运用组卷积与点卷积进行特征提取和融合,而不确定的冗余信息则采用轻量级的PConv进行隐藏细节信息处理,如式(14)所示。

$$X_1^{\frac{c}{2}} = Cv_l(X^c, X^{\frac{c}{2}}, Dim = 1) \quad (11)$$

$$X_2^{\frac{c}{2}} = SA - Conv(X_1^{\frac{c}{2}}) \quad (12)$$

$$X_3^{\frac{c}{2}} = P - Conv(SiLU(BN_2(DW - Conv(X_2^{\frac{c}{2}})))) \quad (13)$$

$$X_4^{\frac{c}{2}} = G - Conv(X_3^{\frac{c}{2}}) + P - Conv(X_3^{\frac{c}{2}}) \quad (14)$$

通过残差连接将输出特征与原始特征融合,解决了神经网络中的梯度消失和梯度爆炸问题,如式(15)所示。最后使用SA-Conv Module、DS-Conv、SP-Conv与残差结构组成的残差模块进行特征堆积,如式(16)和(17)所示,其中 i 表示残差块的个数。通过上述操作构造的WDFE-Module能够增强网络对多尺度特征的提取和表示,提高模型的检测性能。

$$X_5^{\frac{c}{2}} = X_4^{\frac{c}{2}} + X_1^{\frac{c}{2}} \quad (15)$$

$$X_6 = \sum_{i=1}^n (X_1 + X_5^{i-1}) \quad (16)$$

$$x_{out} = Conv_2(Cat(X, X_6)) \quad (17)$$

2 实验与分析

2.1 数据集与实验设计

为了验证所提方法的有效性 with 泛化性能,本文分别在自制超声波焊接缺陷数据集与公开数据集NEU-DET进行了相关对比实验。对于超声波焊接数据集,本文根据美国汽车工程师协会SAE MOBILUS平台颁发的超声波焊接线端接头性能规范USCAR38-1标准,研究将典型和常见的焊接缺陷如图5所示。分别为断芯丝、芯丝烧焦、芯丝污渍、芯丝末端脱落和芯丝鼓起(以下简称断芯、烧焦、线芯污渍、侧边脱落、鼓起)。这些缺陷呈现出不同的形状和尺度,且部分缺陷有着背景复杂与不明显的特征。本文方法共采集具有焊接缺陷的线束783幅。通过数据增强将图像扩展到2349幅。本文将数据集按照8:1:1的比例划分为训练集、验证集、测试集。

对于NEU-DET公开数据集,是由东北大学发布的表面缺陷数据集^[21]。该数据集包含了1800幅灰度图像,包括带钢表面的6种典型表面缺陷,如图6所示,分别是裂纹(crazing)、涂层剥落(inclusion)、斑块(patches)、辊印(rolled-in scale)和划伤(scratch)、点蚀(pitted surface)。本方法同样按照8:1:1的比例进行数据集的划分。本文方法和相关消融实验均在NVIDIA GeForce RTX 4080上进行300Epoch的训练。输入图像

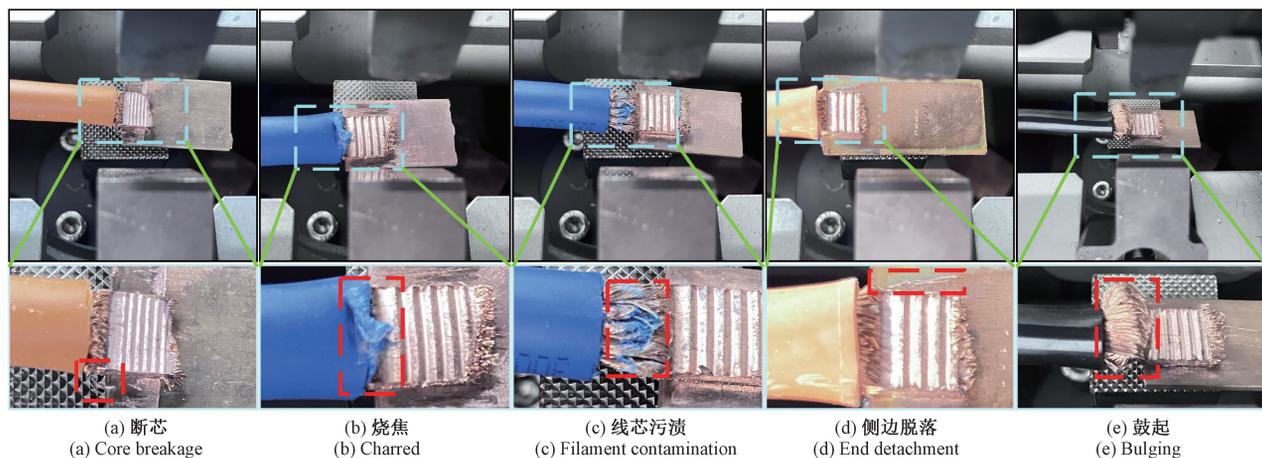


图 5 不同类型焊接缺陷示意图

Fig. 5 Schematic diagram of different types of welding defects

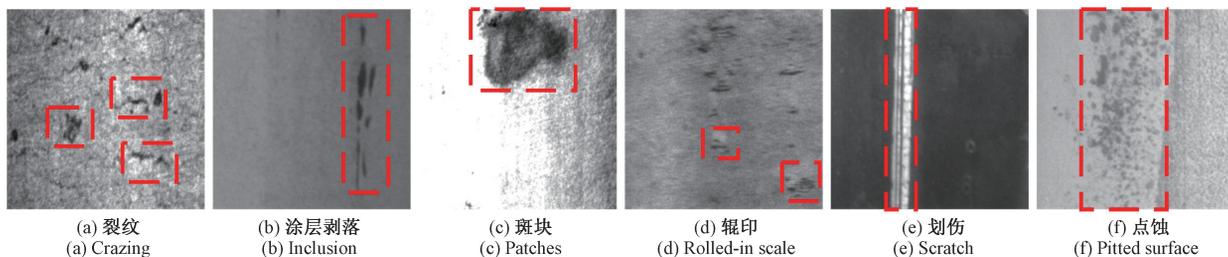


图 6 不同类型带钢表面缺陷示意图

Fig. 6 Schematic diagram of different types of strip surface defects

大小均设置为 640×640 , Batch size 均设置为 16。模型最大学习率与最小学习率分别为 0.01 和 0.000 1。本算法采用 SGD 优化器, Momentum 参数设置为 0.937。权重衰减的强度 0.000 5, 参数随机种子为 16, 并采用了余弦退火的学习率衰减策略。

实验中, 使用精度 (precision)、召回率 (recall)、F1、平均精度均值 (mean average precision, mAP)、每秒帧数 (FPS) 与推理时间作为实验评估超声波焊接线束缺陷检测的标准, 这些指标对于工业应用具有重要的参考价值。其中, 精度如式 (18) 所示计算, 通常用于评估模型的准确性。召回率如式 (19) 所示计算, 通常用于评估模型对于正样本的检测能力。

$$Precision = \frac{TP}{(TP + FP)} \quad (18)$$

$$Recall = \frac{TP}{(TP + FN)} \quad (19)$$

式中: TP (true positive) 表示模型正确地检测出的正样本; FP (false positive) 表示模型错误地将负样本检测为正样本; FN (false negative) 表示模型错误地将正样本预测为负样本。F1 计算如式 (20) 所示。F1 性能评价指标综

合考虑了模型的精确度和召回率。由于缺陷类型数量不平衡, 所以 F1 指标能够在类别不平衡下提供更全面的评估。mAP@0.5 是指交并比 (IoU) 阈值在 0.5 时的平均精度值, 即预测边界框与真实边界框重叠层度高于 50% 时认为预测结果为正样本, mAP 计算如式 (21) 所示。FPS 计算如式 (22) 所示。

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (20)$$

$$mAP = \frac{\sum_{i=1}^k AP_i}{k} \quad (21)$$

$$FPS = \frac{1\ 000\ ms}{Preprocess + Inference + Postprocess} \quad (22)$$

式中: $Preprocess$ 、 $Inference$ 与 $Postprocess$ 分别表示单帧的预处理时间、推理时间和后处理时间。

2.2 消融实验

为了探索提出的各个模块对于超声波焊接线束缺陷检测的有效性与适用性。本文进行了一系列的消融实验。实验思路为首先验证本文方法所提出的分步卷积与注意力机制结合的有效性。其次验证 DCN-Module 加入网络中的有效性。实验结果如表 1 所示。其中 0%、

25%、100%分别表示特征通道数进行 CBAM 注意力机制操作的占比。

表 1 消融实验

Table 1 Ablation experiments

WDFE-Module			DCN-Module	Precision/ %	Recall/ %	F1	mAP@0.5/ %
0%	25%	100%					
√			√	94.1	91.8	0.916	91.7
	√		√	94.1	94.1	0.941	91.9
		√		95.4	92.0	0.941	92.6
		√	√	96.1	94.4	0.952	93.6

从表 1 可以看出,在不使用注意力机制的情况下, WDFE-Module 中的 SA-Conv 架构仍能实现较为优异的性能,具体表现为 Precision、Recall、F1 和 mAP@0.5 分别达到 94.1%、91.8%、0.916 和 55.6%。这一结果表明,SA-Conv 模块显著增强了网络对缺陷区域关键特征的捕捉能力,从而有效提高了模型在缺陷识别中的表现。尽管没有引入注意力机制,该架构依然能够较好地提取缺陷特征,展示了其在特征提取方面的潜力。当对特征图前 25% 的通道使用注意力时, F1 获得了较大的提升,比基线模型高出了 2.5%。mAP@0.5 也获得了小幅度的提升。显著性能提升的原因在于分步卷积中引入了 CBAM 注意力机制,该机制使得网络能够更加有效地关注并利用焊接缺陷的关键特征信息。同时, CBAM 机制有助于防止关键信息的丢失,从而增强了网络对焊接缺陷特征空间位置变化的捕捉能力。这一改进使得模型能够更精确地识别和定位各类焊接缺陷,提高了检测的准确性和

表 2 不同注意力机制对比实验结果

Table 2 Results of experiments comparing different attention mechanisms

模块	Precision/%	Recall/%	F1	mAP@0.5/%	帧率/fps	推理时间/ms
CoordAttention	94.3	91.5	0.916	91.6	125.00	7.88
Triple Attention	93.2	91.7	0.909	90.9	107.53	9.23
SKAttention	93.8	80.5	0.875	87.5	121.50	8.05
SimAM	87.5	92.0	0.861	86.1	134.05	7.37
LSKAttention	92.4	90.5	0.916	91.6	114.52	8.66
UWD-Net (本文)	96.1	94.4	0.952	93.6	145.80	6.72

从表 2 可以发现,所使用的 SA-Conv 架构的 Precision 和 Recall 分别达到了 96.1% 与 94.4%,在分步卷积与 6 个不同注意力机制结合的架构中精度与召回都最高。在 F1 与 mAP@0.5 检测性能评价指标中,SA-Conv 架构分别达到了 0.952 与 93.6%。相比于其他组合架构展现出优异的表面缺陷检测性能。SA-Conv 架构之所以表现出优异的性能是由于分步卷积使用 3×3 普通卷积核对代表性缺陷特征进行空间特征提取。并使用点卷积层对冗余缺陷特征进行了空间融合,有效避免缺陷特征信息的丢失。最后通过 CBAM 注意力机制中的空间注意力模块与通道注意力模块,使得缺陷特征信息被网

鲁棒性。当对所有通道进行注意力操作时, F1 与 mAP@0.5 都获得了提升,分别比基线模型提升了 3.6% 与 1.9%。这是由于在检测侧边脱落等位置随机的缺陷时,空间注意力模块在特征图的不同位置上赋予不同的权重,更有效地赋予这些区域较大的权重。因此这有助于模型更有针对性地关注缺陷所在的空间位置,提高对这类缺陷的检测性能。最后通过对比是否采用 DCN-Module 实验发现,采用了 DCN-Module 的 Precision (96.1%)、Recall (94.4%)、F1 (0.952) 与 mAP@0.5 (93.6%) 比未采用 DCN-Module 的 Precision、Recall、F1 与 mAP@0.5 高出了 0.7%、2.4%、1.1% 与 1%。通过采用 DCN-Module,网络能够通过学习参数来动态调整卷积核的形状和偏移,从而更好地适应焊接缺陷特征的空间变化。这种灵活性使得模型能够更加精确地捕捉不规则焊接缺陷(如侧边脱落和芯丝鼓起)的特征,并有效提升了缺陷特征的提取能力。该模块显著增强了模型对复杂缺陷形态的适应性,有助于提高对不同类型焊接缺陷的识别精度。

2.3 不同注意力机制对比实验

为验证 SA-Conv 架构在关键焊接缺陷特征信息感知方面的卓越性,并深入证明分步卷积与 CBAM 注意力机制的结合更适用于焊接缺陷表面检测任务。因此本文进行了分步卷积与不同注意力机制(CoordAttention^[22]、Triple Attention^[23]、SKAttention^[24]、SimAM^[25]、LSKAttention^[26])结合进行焊接表面缺陷检测的实验,实验结果如表 2 所示。

络模型更好地关注和利用,提高了网络模型的鲁棒性。最后本文方法通过不同模型的 Precision、Recall、F1 分数、mAP@0.5 与推理速度得到簇状图,如图 7 所示。通过对图 7 中不同模型的 Precision、Recall、F1 分数、mAP@0.5 与推理速度的簇状图对比分析可以清楚地看到,UWD-Net 在 Precision、Recall、F1 分数和 mAP@0.5 等各项指标上均优于其他模型,尤其在推理速度方面,表现也十分突出,达到最高值。其他注意力机制模型如 CoordAttention 和 LSKAttention 则在精度和召回率上表现良好,但推理速度相对较慢。SimAM 虽然在推理速度上表现最快,但在精度上稍逊于其他模型。整体来看,

UWD-Net 在性能和速度之间实现了最好的平衡,适合实际应用中的高效表面缺陷检测任务。

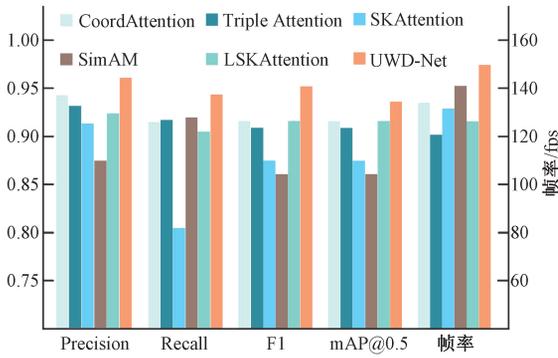


图 7 不同性能评价指标簇状图

Fig. 7 Cluster diagram of different performance evaluation indicators

2.4 不同特征金字塔对比实验

为了验证 SPPF 模块位于焊接缺陷特征提取架构末端能够更有效地捕捉多尺度的焊接缺陷信息,并且可以出色地应对焊接缺陷尺寸多变的特性。本文进行了在特征提取网络末端使用不同特征金字塔结构的实验,以验证 SPPF 能够更好的使得模型充分提取到焊接缺陷的多尺度特征。为保证实验的公平性,所有实验均只改变特征提取网络末尾的特征金字塔结构,其他参数与设置保持一致。实验结果如表 3 所示。

通过实验结果可以发现,在焊接缺陷特征提取网络末端使用 SPPF 能达到较好的表面缺陷检测效果。其中对于各项性能评价指标,采用 SPPF 模块在 Precision、Recall、F1 与 mAP @ 0.5 分别达到了 96.1%、94.4%、95.2%与 93.6%,比其他类型特征金字塔性能评价指标都高。因此在与其它特征金字塔相比之下,本文所使用

表 3 不同特征金字塔结构对比实验结果

Table 3 Comparative experimental results of different characteristic pyramid structures

算法	Precision/%	Recall/%	F1	mAP@0.5/%	帧率/fps	检测时间/ms
SPP	96.0	92.9	0.944	91.8	136.79	7.22
SmiSPP	95.4	90.8	0.930	90.7	135.14	7.35
BasicRFB	95.8	92.6	0.942	93.2	126.58	7.88
SPPCSPC	94.2	92.9	0.935	90.9	121.95	8.11
SPPFCSPC	94.5	91.9	0.931	91.7	114.94	8.66
SPPF(本文)	96.1	94.4	0.952	93.6	145.80	6.72

的 SPPF 针对于超声波焊接线束表面缺陷检测任务中表现出优异检测效果。由于焊接缺陷表现出形状多变的特性,SPPF 层可以从不同尺度的感受野中提取到缺陷特征信息。通过这种方式,SPPF 架构得以更为全面地捕捉焊接缺陷的细节和上下文信息。因此 SPPF 模块使得焊接缺陷特征提取网络更好地适应了缺陷的复杂形状,并有效地应对了缺陷不同尺度上的变化。

此外,从推理速度方面来看,SPPF 模块的推理速度达到了 145.80 fps,在所有对比模块中表现最为优秀,远高于 SPP (136.79 fps)、SmiSPP (135.14 fps)、BasicRFB (126.58 fps) 等其他模块。高推理速度不仅保证了检测任务的实时性,还表明 SPPF 能够在确保高精度的同时,维持较快的推理速度,适应工业现场对表面缺陷检测实时性和高效性的双重要求。

多层圆环图如图 8 所示,可以发现,本文方法在焊接表面缺陷检测任务中展现出卓越的综合性能,各项性能评价指标远高于其他算法。

2.5 与其他算法对比实验

为进一步验证提出的网络框架在超声波焊接表面缺陷检测任务中的卓越性能,本文使用不同类型的目标检测算法进行了一系列的对比实验。实验结果如表 4 所示。

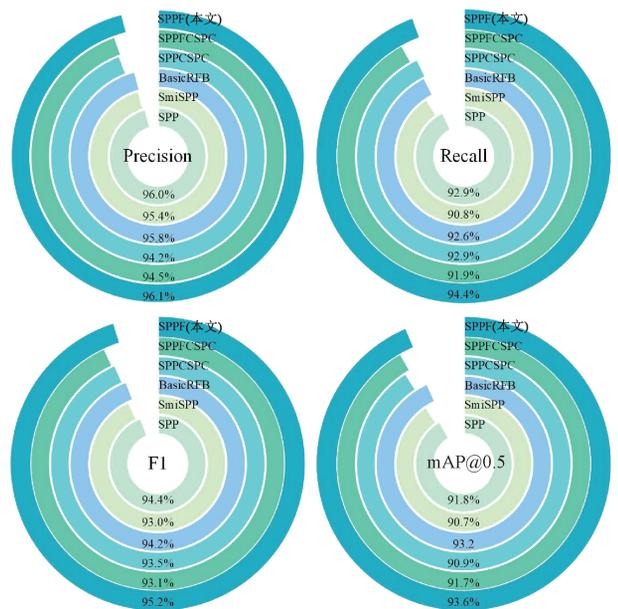


图 8 不同性能评价指标多层圆环图

Fig. 8 Multi-layer circular diagrams for different performance evaluation metrics

并且为了验证 UWD-Net 网络的具有良好的表面缺陷检

测能力与泛化能力,研究在公开数据集 NEU-DET 也进行了与其他类型算法的对比实验,实验结果如表 5 所示。本文对比了基于 Transformer 框架的目标检测算法 RT-

DETR^[27],以及单阶段目标检测算法 YOLOX^[28]。另外,还进行了与双阶段目标检测算法相关的 Faster-RCNN^[29]和轻量级网络 Efficient-Det^[30]的对比实验。

表 4 超声波焊接表面缺陷的不同检测算法实验结果

Table 4 Experimental results of different detection algorithms for ultrasonic welding surface defects

算法	Precision/%	Recall/%	F1	mAP@0.5/%	Parameters/($\times 10^6$)	浮点数/GFLOPs	帧率/fps	推理时间/ms
RT-DETR	91.2	88.1	0.896	90.6	66.200	110.000	36.36	27.36
YOLOX	95.9	93.1	0.945	92.2	8.939	26.766	88.65	11.21
Faster-RCNN	62.0	96.2	0.752	91.2	137.099	370.210	35.46	27.88
Efficient-Det	88.8	69.6	0.665	75.2	3.830	4.762	97.08	10.27
UWD-Net(本文)	96.1	94.4	0.952	93.6	1.818	4.039	145.80	6.72

由表 5 可以发现,本文提出的算 UWD-Net 的 F1 为 0.952,与 RT-DETR (0.896)、YOLOX (0.945)、Faster-RCNN(0.752)和 EfficientDet (0.665)相比分别高出了 5.6%、0.7%、20.0%和 28.7%。实验结果表明,本文方法在 F1 性能评价指标取得较高的得分表明算法在精度和召回之间取得了较好的平衡。较高的 F1 值意味着本文算法能够有效地识别焊接缺陷,同时最小化误报。并且本文算法在阈值为 0.5 时的平均精度达到了 93.6%,与 RT-DETR (90.6%)、YOLOX (92.2%)、Faster-RCNN (91.2%)和 EfficientDet(75.2%)相比分别高出了 3.0%、1.4%、2.4%和 18.4%。说明 UWD-Net 在不同尺度和难度的焊接缺陷检测上取得了高度准确的结果,因此这对于确保焊接质量和缺陷预防在实际工业场景应用具有关键的意义。

关于推理性能,尽管本文方法提出的算法在检测精度方面表现优异,但其推理速度和计算资源消耗同样值得关注。根据实验结果,UWD-Net 在推理过程中的平均延迟为 6.72 ms,且单张图像推理时的帧率为 145.80 fps。与其他算法相比,UWD-Net 在推理速度上表现出了显著优势,能够在保证较高检测精度的同时实现更高效的实时处理。

不同性能评价指标柱状图如图 9 所示,可以观察到 UWD-Net 在精度与参数量之间达到了良好的平衡,且在各项性能评价指标上均优于其他对比方法。具体而言,UWD-Net 在模型参数量(1.818×10^6)方面显著低于其他算法,尤其是在计算资源消耗方面表现突出。这一优势使得 UWD-Net 在实际应用中更具可行性,特别是在嵌入式设备的部署中,能够更好地适应工业环境中的计算资源限制和实时性要求。

通过在公开数据集 NEU-DET 进行不同算法的对比实验,其实验结果如表 5 所示。可以观察到 UWD-Net 算法在 NEU-DET 数据集上的 Precision、Recall、F1 和 mAP@0.5 分别达到了 86.9%、60.0%、0.710 和 78.6%,相比于其他目标检测算法表现的更好。特别是在 F1 与 mAP@0.5

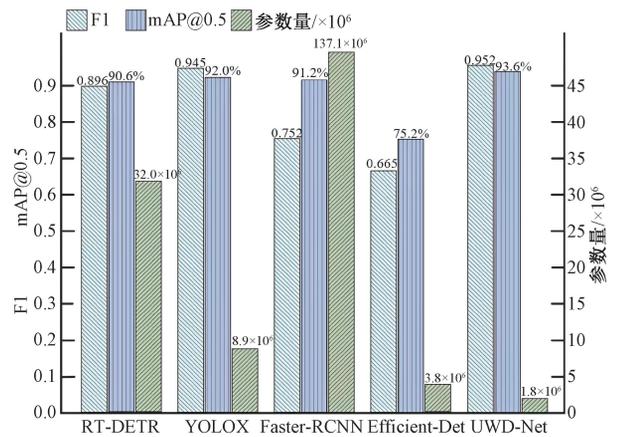


图 9 不同性能评价指标柱状图

Fig. 9 Histogram of different performance evaluation indicators

检测性能评价指标上。如在 F1 评价指标上,分别比 RT-DETR(0.446)、YOLOX(0.599)、Faster-RCNN(0.283)和 EfficientDet (0.517)高出了 26.4%、11.1%、42.7%和 40.0%,并且 mAP@0.5 分别也比 RT-DETR(39.1%)、YOLOX(68.0%)、Faster-RCNN(73.3%)和 EfficientDet(51.7%)分别高出了 39.5%、10.6%、5.3%和 26.9%。并且通过实验结果可以发现,UWD-Net 在每秒处理具有缺陷图像时,能够达到 144.50 fps,展现出了更强的实时处理能力。这一优势使得 UWD-Net 在高效生产环境中具备更高的应用价值。此外,实验结果表明 UWD-Net 在不同缺陷类型的数据集上表现出较高的检测精度和稳定性,证明其不仅适用于焊接缺陷检测,还具备较好的泛化能力。

不同检测算法混淆矩阵图如图 10 所示,可以看出 UWD-Net 在所有缺陷类别上的分类性能均优于其他算法,尤其在 Class 1(inclusion)、Class 2(patch)和 Class 4(rolled-in_scale)上的分类准确率较高,展现出卓越的缺陷检测能力。相比之下,YOLOX 和 Faster-RCNN 的整体表现较为稳定,但在某些类别上仍存在一定混淆,而 RT-

表 5 NEU-DET 不同检测算法实验结果

Table 5 Experimental results of different detection algorithms of NEU-DET

算法	Precision/%	Recall/%	F1	mAP@0.5/%	Parameters/ $\times 10^6$	浮点数/GFLOPs	帧率/fps	推理时间/ms
RT-DETR	68.8	33.6	0.446	39.1	66.200	110.000	36.50	27.22
YOLOX	79.8	46.9	0.599	68.0	8.939	26.766	87.64	11.33
Faster-RCNN	16.8	90.4	0.283	73.3	137.099	370.210	36.31	27.54
EfficientDet	71.2	19.8	0.310	51.7	3.830	4.762	98.23	10.08
UWD-Net(本文)	86.9	60.0	0.710	78.6	1.818	4.904	144.50	6.81

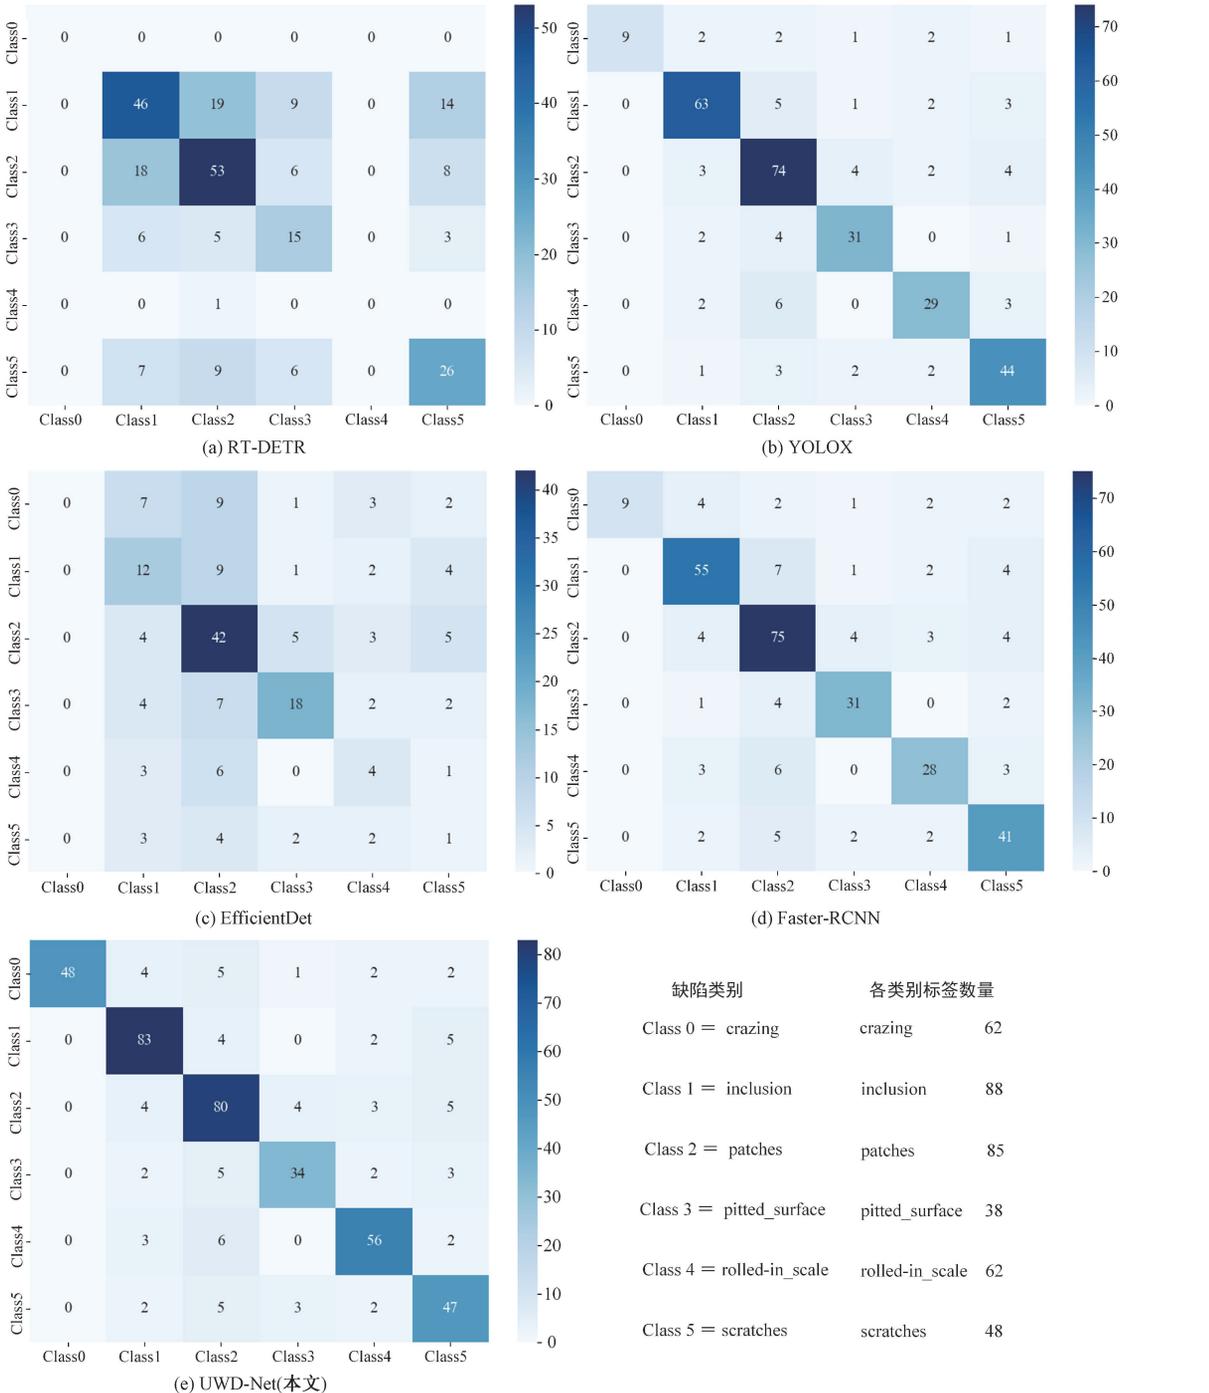


图 10 不同检测算法混淆矩阵图

Fig. 10 Confusion matrix diagram of different detection algorithms

DETR 和 EfficientDet 的分类能力相对较弱,尤其在 Class 3 (pitted_surface) 和 Class 5 (scratches) 上表现不佳。因此 UWD-Net 在复杂背景下的钢材表面缺陷检测任务中表现出更强的鲁棒性和分类能力,验证了其网络结构的有效性 与泛化性。

11 所示,发现 UWD-Net 算法在焊接缺陷上能够较高精度地框选出具有缺陷的位置,实现了高精度的缺陷检测。此外,在钢材表面缺陷检测上也展现出优异的检测效果,这表 明了 UWD-Net 算法具备一定的泛化能力,能够适应多样化的数据集和实际应用场景。

超声波焊接线束缺陷与钢材表面缺陷检测效果如图

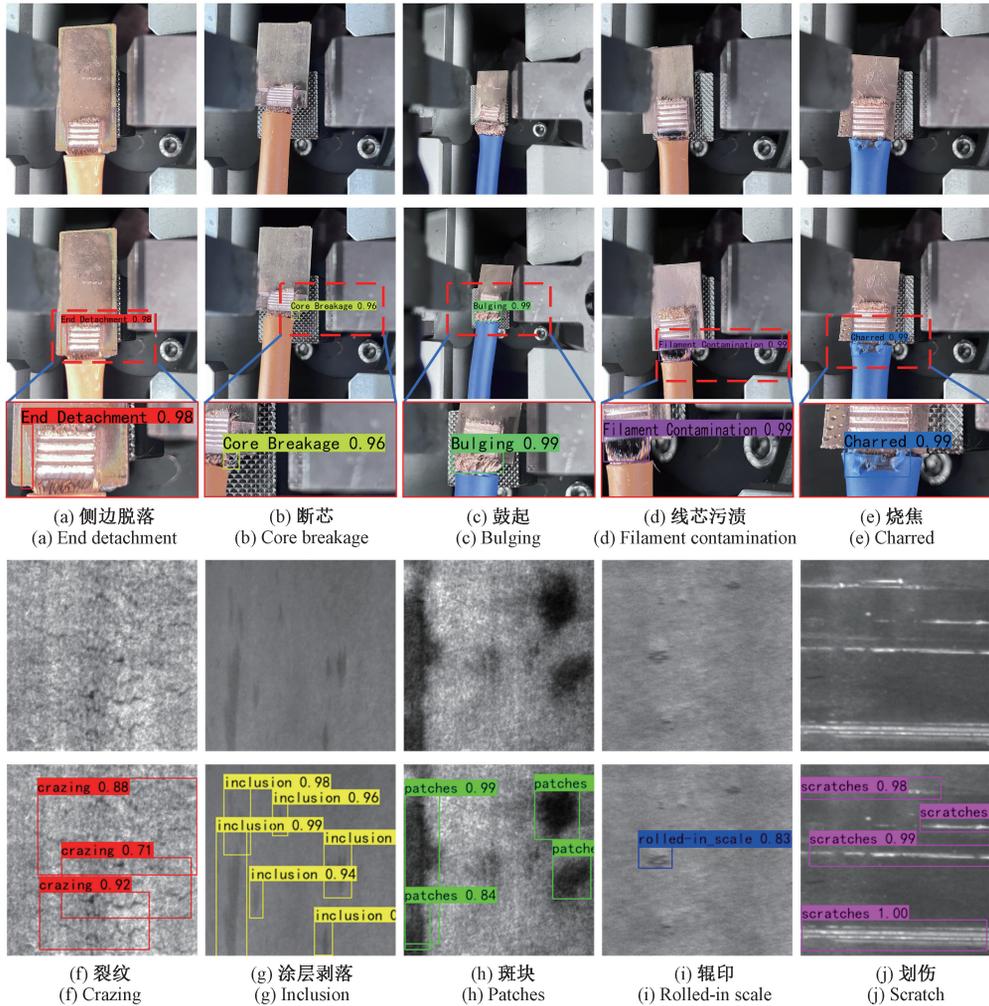


图 11 超声波焊接线束缺陷与钢材表面缺陷检测效果

Fig. 11 Ultrasonic welding harness defects and steel surface defects detection effect diagram

3 结 论

由于线束缺陷具有背景复杂、形状多变、位置随机和缺陷类型复杂等特点,传统的焊接缺陷检测方法难以达到高效准确的检测结果。因此本文提出了一种新型的超声波焊接线束表面缺陷检测算法 UWD-Net。首先,针对传统卷积对细节信息不敏感,且容易丢失关键细小缺陷特征信息等问题。本文提出了一种新型 SA-Conv 卷积模块,该模块的使用不仅有助于降低设备的运算成本,而且增强了模型对关键特征信息的感知能力。其次,通过设

计基于 WDFE-Module 与 DCN-Module 的焊接缺陷特征提取网络架构,使得复杂缺陷信息能够被充分提取,提高了网络的特征提取能力。最后,通过在超声波焊接线束缺陷数据集和 NEU-DET 公开数据集进行实验对比,有效证明了 UWD-Net 检测算法在焊接表面缺陷与钢材表面缺陷检测任务中具有较好的鲁棒性与泛化性。

然而,本文方法仍然存在一些局限性,因此在后续的算法优化中,将采用知识蒸馏技术来减小模型的计算量并提高检测效率。并且针对缺陷类型对损失函数进行设计与优化,提高模型的泛化能力。

参考文献

- [1] ZHAO D, REN D, ZHAO K, et al. Ultrasonic welding of magnesium-titanium dissimilar metals: A study on thermo-mechanical analyses of welding process by experimentation and finite element method[J]. Chinese Journal of Mechanical Engineering, 2019, 32(1): 1-11.
- [2] 赵佰亭,张晨,贾晓芬. ECC-YOLO:一种改进的钢材表面缺陷检测方法[J]. 电子测量与仪器学报, 2024, 38(4): 108-116.
- ZHAO B T, ZHANG CH, JIA X F. ECC-YOLO: An improved method for steel surface defect detection [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38 (4): 108-116.
- [3] 侯一帆,楼佩煌,钱晓明,等. 基于机器视觉的手机屏幕 Mura 缺陷检测方法研究[J]. 机械设计与制造工程, 2024, 53(6): 87-90.
- HOU Y F, LOU P H, QIAN X M, et al. Research on mura defect detection method for mobile phone screens based on machine vision [J]. Mechanical Design and Manufacturing Engineering, 2024, 53(6): 87-90.
- [4] 张立亭,黄晓浪,鹿琳琳,等. 基于灰度差分与模板的 Harris 角点检测快速算法[J]. 仪器仪表学报, 2018, 39(2): 218-224.
- ZHANG L T, HUANG X L, LU L L, et al. Fast Harris corner detection algorithm based on gray difference and template[J]. Chinese Journal of Scientific Instrument, 2018, 39(2): 218-224.
- [5] 武琪凯. 基于改进支持向量机的材料缺陷识别系统[D]. 南京:南京邮电大学, 2023.
- WU Q K. Material defect recognition system based on improved support vector machine [D]. Nanjing: Nanjing University of Posts and Telecommunications, 2023.
- [6] SASSI P, TRIPICCHIO P, AVIZZANO C A. A smart monitoring system for automatic welding defect detection[J]. IEEE Transactions on Industrial Electronics, 2019, 66(12): 9641-9650.
- [7] 李辉,董燕,刘祥,等. 基于两阶段深度网络的输电线路异常目标检测方法[J]. 控制与决策, 2022, 37(7): 1873-1882.
- LI H, DONG Y, LIU X, et al. Abnormal target detection method for transmission lines based on two-stage deep network [J]. Control and Decision, 2022, 37 (7): 1873-1882.
- [8] 周鑫,郝万君,卞长庚,等. 基于 $g \sim n$ Conv 和 GAM 的 YOLOv5 钢管焊接缺陷检测方法[J]. 微电子学与计算机, 2023, 40(9): 29-37.
- ZHOU X, HAO W J, BIAN CH G, et al. Welding defect detection method for steel pipes based on $g \sim n$ Conv and GAM in YOLOv5 [J]. Microelectronics & Computers, 2023, 40(9): 29-37.
- [9] TAO X, ZHANG D, MA W, et al. Automatic metallic surface defect detection and recognition with convolutional neural networks[J]. Applied Sciences, 2018, 8(9): 1575.
- [10] WANG P, SONG L, WANG H, et al. Grouping sparse filtering: A novel down-sampling approach toward rotating machine intelligent diagnosis in 1D-convolutional neural networks [J]. Measurement Science and Technology, 2022, 33(6): 065111.
- [11] NIU Z, ZHONG G, YU H. A review on the attention mechanism of deep learning[J]. Neurocomputing, 2021, 452: 48-62.
- [12] XING J, JIA M. A convolutional neural network-based method for workpiece surface defect detection [J]. Measurement, 2021, 176: 109185.
- [13] LIU Y, ZHENG Y, SHAO Z, et al. Defect detection of the surface of wind turbine blades combining attention mechanism [J]. Advanced Engineering Informatics, 2024, 59: 102292.
- [14] CHEN J, WANG H B, LI H. Defects detection in weld joints based on visual attention and deep learning[J]. NDT & E International, 2023, 133: 102764.
- [15] MA J, HU S, FU J, et al. A hierarchical attention detector for bearing surface defect detection[J]. Expert Systems with Applications, 2024, 239: 122365.
- [16] HAN K, WANG Y, TIAN Q, et al. Ghostnet: More features from cheap operations [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 1580-1589.
- [17] 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.
- [18] 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.
- [19] CHOLLET F. Xception: Deep learning with depthwise separable convolutions [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1251-1258.
- [20] ZHANG Q, JIANG Z, LU Q, et al. Split to be slim: An overlooked redundancy in vanilla convolution[J]. ArXiv preprint arXiv:2006.12085, 2020.
- [21] BAO Y, SONG K, LIU J, et al. Triplet-graph reasoning network for few-shot metal generic surface defect segmentation [J]. IEEE Transactions on Instrumentation

- and Measurement, 2021, 70: 1-11.
- [22] 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.
- [23] MISRA D, NALAMADA T, ARASANIPALAI A U, et al. Rotate to attend: Convolutional triplet attention module [C]. Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision, 2021: 3139-3148.
- [24] LI X, WANG W, HU X, et al. Selective kernel networks [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 510-519.
- [25] YANG L, ZHANG R Y, LI L, et al. Simam: A simple, parameter-free attention module for convolutional neural networks [C]. International Conference on Machine Learning. PMLR, 2021: 11863-11874.
- [26] LAU K W, PO L M, REHMAN Y A U. Large separable kernel attention: Rethinking the large kernel attention design in CNN [J]. Expert Systems with Applications, 2024, 236: 121352.
- [27] LYU W, XU S, ZHAO Y, et al. Detrs beat YOLOs on real-time object detection [J]. ArXiv preprint arXiv: 2304.08069, 2023.
- [28] GE Z, LIU S, WANG F, et al. YOLOX: Exceeding YOLO series in 2021 [J]. ArXiv preprint arXiv: 2107.08430, 2021.
- [29] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. Advances in Neural Information Processing Systems, 2015, 28.
- [30] TAN M, PANG R, LE Q V. Efficientdet: Scalable and efficient object detection [C]. Proceedings of the IEEE/

CVF Conference on Computer Vision and Pattern Recognition, 2020: 10781-10790.

作者简介



梁峰, 2022 年于四川文理学院获得学士学位, 现为昆明理工大学硕士研究生, 主要研究方向为深度学习、目标检测和缺陷检测。

E-mail: liang728885256@163.com

Liang Feng received his B. Sc. degree from Sichuan University of Arts and Sciences in 2022. He is currently a M. Sc. candidate at Kunming University of Science and Technology. His main research interests include deep learning, target detection, and defect detection.



赵伦 (通信作者), 2017 年于瑞典布京理工学院获得博士学位, 现为深圳职业技术大学特聘副研究员, 主要研究方向为自冲铆接、超声焊接、机器人和缺陷检测。

E-mail: zhaolun_ultrasonic@126.com

Zhao Lun (Corresponding author) received his Ph. D. degree from the Royal Institute of Technology (KTH) in Sweden in 2017. He is currently a distinguished associate researcher at Shenzhen Polytechnic. His main research interests include self-piercing riveting, ultrasonic welding, robotics, and defect detection.



王森, 2017 于昆明理工大学获得博士学位, 现为昆明理工大学副教授, 主要研究方向视觉感知与测量、二维/三维视觉振动测量和工业视觉状态检测。

E-mail: Wangsen0401@126.com

Wang Sen received his Ph. D. degree from Kunming University of Science and Technology in 2017. He is currently an associate professor at Kunming University of Science and Technology. His main research interests include visual perception and measurement, 2D/3D visual vibration measurement, and industrial visual condition monitoring.