

DOI:10.3969/j.issn.1003-5060.2023.12.010

基于 CR-RFPR101 的钢板表面缺陷检测

李雪露, 储茂祥, 杨永辉, 刘光虎

(辽宁科技大学 电子与信息工程学院, 辽宁 鞍山 114051)

摘要:针对钢板表面缺陷种类多、背景复杂、检测精度低等问题,文章首先对钢板表面缺陷数据集进行数据增强,并对原始 Cascade 区域卷积神经网络(region-based convolutional neural networks,R-CNN)算法进行改进,将 ResNeXt-101-64 \times 4d 作为 Cascade R-CNN 算法的骨干网络,优化特征提取模块,利用递归特征金字塔(recursive feature pyramid,RFP)网络以反馈连接的方式进行特征优化,提出一种 CR-RFPR101(Cascade R-CNN RFP ResNeXt-101-64 \times 4d)的检测算法,以更好地保留细节和语义信息;同时使用可切换的空洞卷积替换主干网络的卷积层,以改变感受野的方式提高检测性能;最后使用引入软化非极大值抑制算法,保留有效信息,提高识别率。经实验验证,CR-RFPR101 算法的检测率为 83.4%,比原 Cascade R-CNN 算法提高了 7.3%,满足了钢板表面缺陷检测要求。

关键词:缺陷检测;数据增强;递归特征金字塔(RFP);可切换的空洞卷积;软化非极大值抑制(Soft-NMS)

中图分类号:TP391.41

文献标志码:A

文章编号:1003-5060(2023)12-1651-08

Surface defect detection of steel plate based on CR-RFPR101

LI Xuelu, CHU Maoxiang, YANG Yonghui, LIU Guanghu

(School of Electronics and Information Engineering, University of Science and Technology Liaoning, Anshan 114051, China)

Abstract:In view of the multiple types, complex background and low detection accuracy of steel plate surface defects, the data set is enhanced and the original Cascade region-based convolutional neural networks(R-CNN) algorithm is improved. ResNeXt-101-64 \times 4d is used as the backbone network of Cascade R-CNN algorithm to optimize feature extraction module. The recursive feature pyramid(RFP) network is used to optimize the features in the way of feedback connection, and a detection algorithm based on Cascade R-CNN RFP ResNeXt-101-64 \times 4d(CR-RFPR101) is proposed to better retain the details and semantic information. Switchable atrous convolution is proposed to replace the convolution layer of the backbone network to improve the detection performance by changing the receptive field. Finally, the soft non-maximum suppression(Soft-NMS) algorithm is introduced to retain the effective information and improve the recognition rate. The experiment shows that the detection rate of CR-RFPR101 algorithm is 83.4%, which is 7.3% higher than that of the original Cascade R-CNN algorithm. The proposed algorithm meets the requirements of steel plate surface defect detection.

Key words:defect detection; data enhancement; recursive feature pyramid(RFP); switchable atrous convolution; soft non-maximum suppression(Soft-NMS)

钢板在生产和加工过程中,受设备和环境等不可控因素的影响,表面易出现麻点、划痕、压入氧化铁皮等缺陷,这些缺陷严重降低了钢材产品的外观、质量和使用性能^[1-3]。传统的钢板缺陷检

测算法依赖于主观臆断,识别率低,误判和错判的概率大大增加。因此,使用深度学习技术对钢板表面缺陷进行检测十分重要^[4]。

随着深度学习理论和人工智能技术的不断发

收稿日期:2022-05-05;**修回日期:**2022-06-15

基金项目:国家自然科学基金资助项目(21978123);辽宁省高等学校基本科研资助项目(2020LNZD06)

作者简介:李雪露(1997—),女,辽宁葫芦岛人,辽宁科技大学硕士生;

储茂祥(1978—),男,安徽桐城人,博士,辽宁科技大学教授,博士生导师;

杨永辉(1971—),男,辽宁鞍山人,博士,辽宁科技大学教授,博士生导师,通信作者,E-mail:yangyh2636688@163.com.

展与完善,其检测精度较传统检测算法有了显著的提升,并在机器视觉领域取得令人瞩目的结果^[5]。文献[6]提出一种基于 DMSA-YOLOv3 模型的缺陷检测,用于检测微小钢板缺陷;文献[7]提出使用 GoogLeNet 作为骨干网络和添加映射的卷积神经网络缺陷分类算法;文献[8]提出使用尺度不变特征转换(scale-invariant feature transform, SIFT)和神经网络相结合的检测算法;文献[9]提出一种基于模板匹配的带钢表面缺陷检测算法;文献[10]提出一种基于 U-Net 的钢板缺陷分割网络;文献[11]改进了 YOLOv3 的骨干网络,并引入空洞卷积和 Inception 模块用于钢板检测;文献[12]提出使用改进的 Mask 区域卷积神经网络(region-based convolutional neural networks, R-CNN)模型钢板表面缺陷检测;文献[13]进一步提出 ResNet50 的 Faster R-CNN 检测网络。

为了弥补传统检测算法的不足,本文提出一种基于 Cascade R-CNN^[14] 的递归特征金字塔 ResNeXt-101-64 × 4d(Cascade R-CNN-recursive feature pyramid ResNeXt-101-64 × 4d, CR-RFP101)的检测算法。为了解决随着网络层数的加深,进行特征提取时产生的梯度消失和梯度爆炸等问题,

提出使用 ResNeXt-101-64 × 4d 网络作为 Cascade R-CNN 算法的骨干网络。为了增加全局特征,引入递归特征金字塔(recursive feature pyramid, RFP)^[15] 代替原主干网络的经典特征金字塔。使用可切换的空洞卷积(switchable atrous convolution, SAC)代替传统卷积层,使用不同空洞率的卷积层对相同的输入特征做卷积。为了实现准确高效的钢板表面缺陷检测,利用线性加权形式的软化非极大值抑制(soft non-maximum suppression, Soft-NMS)^[16] 算法对模型的非极大值抑制(non-maximum suppression, NMS)结构^[17] 进行优化,提高准确性。

1 Cascade R-CNN

1.1 Cascade R-CNN 网络结构

Cascade R-CNN 模型主要由特征提取网络 ResNet101^[18]、区域建议网络(region proposal network, RPN)和级联检测器组成。Cascade R-CNN 网络结构如图 1 所示。采用 ResNet101 网络对钢板表面缺陷图像进行特征提取,然后将提取的缺陷特征输入到 RPN 进行候选区域选择,最后使用级联检测器实现缺陷的定位和分类。

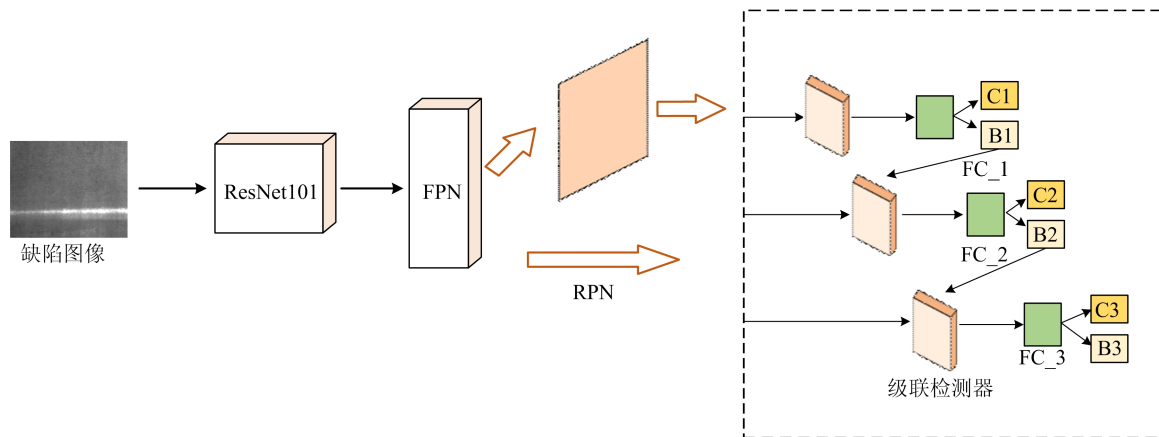


图 1 Cascade R-CNN 网络结构图

1.2 级联结构

Cascade R-CNN 具有独特的级联结构,实现了更加准确地定位缺陷信息。3 个级联结构的 IoU 阈值依次设置为 $[0.5, 0.6, 0.7]$ 。

首先将预测框送入 IoU 阈值为 0.5 的检测网络,若此时预测框与真实框之间的 IoU 阈值 > 0.5 ,则判断该框为正类,引入边框回归损失 B1 调整预测框的边框位置,同时生成第 1 个分类得分 C1。

将 B1 修正后的新区域经过筛选的候选框送入 IoU 阈值为 0.6 的检测网络,若此时 IoU 阈值 > 0.6 ,则仍判断该框为正类,同时利用边框回归损失 B2 调整预测框的边框位置并生成第 2 个分类得分 C2;依此类推,最后得到钢板表面缺陷的最终分类得分以及定位信息。

2 改进的 Cascade R-CNN

改进后的 Cascade R-CNN 网络结构如图 2

所示。

首先,将采集到的钢板表面缺陷图像输入到基于 ResNeXt-101-64 × 4d 的特征提取网络。然后,利用特征金字塔结构代替传统特征金字塔结构进行特征融合。

其次,引入 SAC 模块,利用空洞卷积改变

卷积核感受野的大小,使用不同空洞率的卷积层对相同的输入特征做卷积,提高特征之间的相关性。

最后,将带有置信度的锚框送入级联检测器,通过 Soft-NMS 模块获取置信度最高的预测框,实现缺陷的定位和分类。

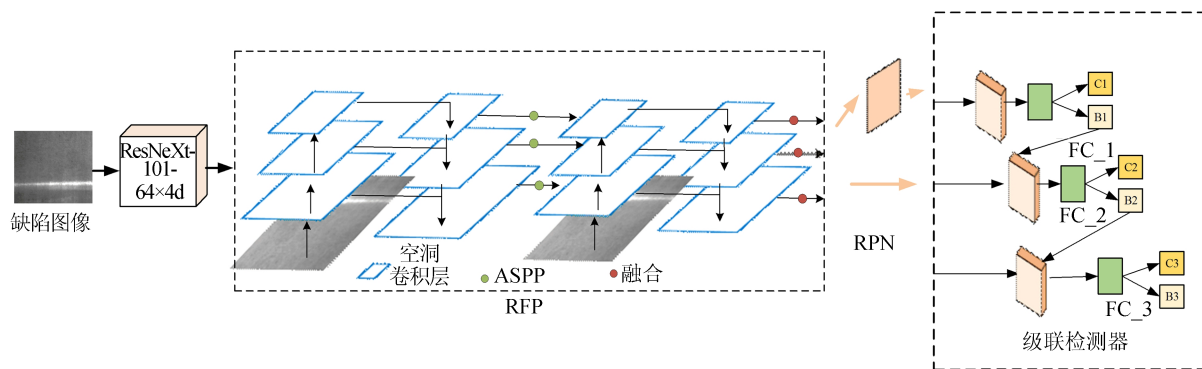


图 2 改进的 Cascade R-CNN 网络结构

2.1 特征提取网络

本文选取 ResNeXt-101-64 × 4d 网络代替 Cascade R-CNN 模型的 ResNet101 网络,完成模型的特征提取功能。ResNeXt-101-64 × 4d 网络将 ResNet101 网络的单个卷积改为多支路的卷积,通过增加卷积基数提高模型的准确率,并采用恒等映射的方式完成特征提取。ResNeXt-101-64 × 4d 的模型结构如图 3 所示。




图 3 ResNeXt-101-64 × 4d 模型结构

图 3 中,每一个方框代表一层网络,其中的 3 个数据从左到右依次为输入数据的通道数目、卷积核大小和输出数据的通道数目,共 64 条路径,即基数 cardinality = 64。在不改变计算量的前提下,ResNeXt-101-64 × 4d 网络增加了路径的

数量,各个模块的输出通过求和进行汇总,较好地提高了网络的特征提取能力。

ResNeXt-101-64 × 4d 网络采用 ReLU 函数作为激活函数,计算公式如下:

$$y(x) = \begin{cases} x, & x > 0; \\ 0, & x \leq 0 \end{cases} \quad (1)$$

2.2 递归特征金字塔

特征金字塔 (feature pyramid networks, FPN)^[19] 主要利用深度卷积神经网络解决目标检测过程中存在的多尺度问题。本文采用的递归特征金字塔则是在特征金字塔的基础上,增加反馈机制和重复应用主干模块,迭代融合输出特征图^[20],提升对小目标缺陷的检测性能。

递归特征金字塔网络结构如图 2 中 RFP 模块所示。设 D_n 为主干网络自底向上的第 n 阶段特征提取过程; F_n 为第 n 阶段自上而下的 FPN 运算; f_n 为递归特征金字塔输出的特征图,其中 $n = 1, 2, \dots, S$; S 为特征层数; H_n 表示自顶向下传输到自底向上的过程的预处理操作; x_n 为第 1 次递归时主干网络输出的第 n 阶段特征图,则 f_n 表达式为:

$$\begin{aligned} f_n &= F_n(f_{n+1}, x_n), \\ x_n &= D_n(x_{n-1}, H_n(f_n)) \end{aligned} \quad (2)$$

多次迭代后的特征图输出为:

$$\begin{aligned} f_n^r &= F_n^r(f_{n+1}^r, x_n^r), \\ x_n^r &= D_n^r(x_{n-1}^r, H_n^r(f_n^{r-1})) \end{aligned} \quad (3)$$

其中, r 为迭代次数。

2.3 可切换的空洞卷积

钢板表面缺陷图像进行特征提取的过程中,因为钢板表面缺陷图像之间的差异较大,没有统一的划分标准,需要进行多尺度检测,所以选择合适的卷积核至关重要,以适应不同的感受野。本文选用可切换的空洞卷积 SAC

代替主干网络的传统卷积层,从而在不同的空洞率之间实现对卷积计算的软切换,实现准确高效的检测。基于 SAC 的总体架构如图 4 所示,从图 4 可以看出,SAC 架构主要由基于 SAC 的空洞卷积结构、全局上、下文模块 3 个模块组成。

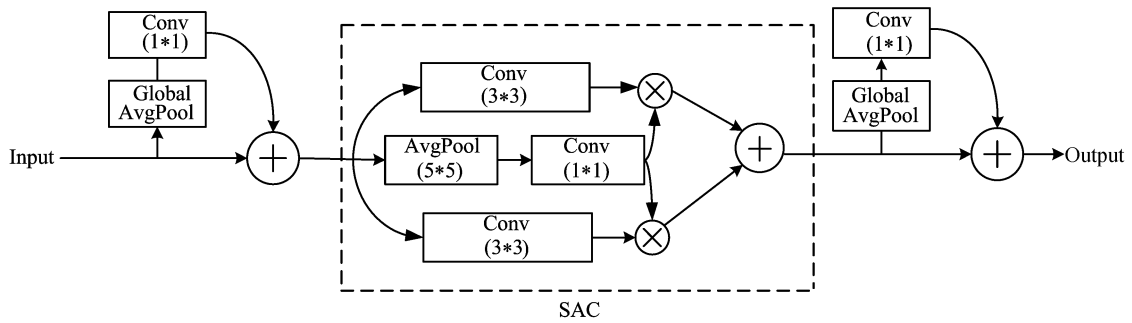


图 4 基于 SAC 的总体架构

SAC 模块的计算公式如下:

$$\text{Conv}(v, w, 1) \rightarrow Y(x) \cdot \text{Conv}(v, w, 1) + (1 - Y(x)) \cdot \text{Conv}(v, w + \Delta w, e) \quad (4)$$

其中: v 为输入; w 为模型权重; e 为空洞卷积的空洞率; Δw 为可训练的权重;函数 $Y(x)$ 由 5×5 的平均池化层和 1×1 卷积层组成。

2.4 非极大值的优化

在检测过程中,由于钢板表面缺陷图像之间的差异较大,RPN 网络会产生大量冗余的锚框,Cascade R-CNN 模型利用 NMS 将重叠的框滤除。然而,经典的 NMS 算法直接将置信度低的锚框过滤掉,只保留一定数量的质量较高的建议框,很容易造成漏检和误检的问题。因此,本文选用基于线性加权形式的 Soft-NMS 算法解决以上问题,将 IoU 阈值设置为 0.7。

当得到较低分数时,不是直接过滤掉,而是进行下一次级联检测,降低漏检的概率,提高模型的检测精度。基于线性加权形式的 Soft-NMS 的计算公式如下:

$$I_k = \begin{cases} I_k, & \text{IoU}(M, b_k) < N_m; \\ I_k(1 - \text{IoU}(M, b_k)), & \text{IoU}(M, b_k) \geq N_m \end{cases} \quad (5)$$

其中: M 为得分最高的框; b_k 为待检测的框; I_k 为最终得分; N_m 为设定的阈值,即 $N_m = 0.7$ 。

3 实验结果与分析

3.1 实验平台

实验运行平台及参数设置见表 1 所列。

表 1 实验运行平台及参数


名称	实验参数
操作系统	Ubuntu 20.04
GPU	NVIDIA GeForce RTX 3090
CPU	Intel(R) Core(TM) i7-10700K
python 版本	python3.7
框架	pytorch
集成开发环境	CUDA11.3
RAM	32 GiB

3.2 缺陷数据集分析与图像增强

本文采用东北大学发布的 NEU-DET 数据集进行实验,其中共计 1 800 张图片,对于 6 类钢板表面缺陷检测是不足的,而数据的缺少会导致训练过拟合以及检测泛化性能较差等问题。

为了解决以上问题,本文采用仿射变换、伽马增强、镜像变换和添加色调和饱和等方式对原始数据进行增强,既增加了数据量,又提高了图像的鲁棒性。增强后的图像为 5 400 张,数量为原来的 3 倍。

数据增强示例图如图 5 所示。






图 5 钢板表面缺陷图像数据增强示例

钢板缺陷图片采用矩形框进行标注,采用 utf-8 的编码格式,200×200 的分辨率,使用 json 记录有关数据,按照 6:2:2 的比例随机分配缺陷图像。

3.3 实验训练

CR-RFPR101 模型使用随机梯度下降 (stochastic gradient descent,SGD) 优化器,每迭代 50 次纪录 1 次损失函数值,训练共迭代 350 次,损失函数随迭代次数的变化如图 6 所示。




图 6 损失函数随迭代次数的变化

从图 6 可以看出,CR-RFPR101 模型的损失

函数值收敛至 0.18 左右趋于稳定,满足训练要求。

3.4 评价指标

本文选用准确率 A (accuracy)、精确率 P (precision) 和召回率 R (recall) 评价模型性能, A 、 P 、 R 计算公式为:

$$A = \frac{T_P + T_N}{T_P + F_P + T_N + F_N} \quad (6)$$

$$P = \frac{T_P}{T_P + F_P} \quad (7)$$

$$R = \frac{T_P}{T_P + F_N} \quad (8)$$

其中: T_P 为钢板无缺陷,预测为无缺陷; F_P 为钢板有缺陷,预测为无缺陷; F_N 为钢板无缺陷,预测为有缺陷; T_N 为钢板有缺陷,预测为有缺陷。

3.5 实验结果分析

为了验证改进的特征提取网络、RFP、SAC 和 Soft-NMS 几个模块对 CR-RFPR101 算法检测效果的影响,设计实验结果见表 2 所列。4 种不同算法的检测结果见表 3 所列。

表 2,表 3 中:Cz 为裂纹缺陷;Is 为夹杂缺陷;Pc 为斑块缺陷;PS 为麻点缺陷;RS 为压入氧化铁皮缺陷;St 为划痕缺陷;mAP 为平均精度均值;AP 为平均精度。从表 2 可以看出,数据增强后的算法 mAP 值为 78.8%,较原始算法提高了 2.7%,有效提高了算法的泛化性能。利用 SAC 代替传统空洞卷积的操作使得 mAP 值增加了 1.5%,能结合不同尺寸的空洞卷积,扩大感受野,提高算法的检测性能。

表 2 改进算法对比

Cascade R-CNN	数据增强	SAC	ResNeXt-101-64×4d	Soft-NMS	RFP	AP 值						mAP 值
						Cz	Is	Pc	PS	RS	St	
✓	—	—	—	—	—	0.359	0.797	0.907	0.921	0.611	0.972	0.761
✓	✓	—	—	—	—	0.545	0.811	0.903	0.868	0.648	0.952	0.788
✓	✓	✓	—	—	—	0.536	0.825	0.905	0.870	0.661	0.963	0.793
✓	✓	✓	✓	—	—	0.577	0.863	0.920	0.875	0.704	0.967	0.818
✓	✓	✓	✓	✓	—	0.606	0.846	0.931	0.860	0.723	0.970	0.823
✓	✓	✓	✓	✓	✓	0.640	0.866	0.926	0.883	0.726	0.965	0.834

表 3 经典算法性能对比

算法	骨干网格	mAP 值	AP 值					
			Cz	Is	Pc	PS	RS	St
SSD	VGG-16	0.797	0.653	0.769	0.916	0.846	0.719	0.881
Faster R-CNN	Darknet-53	0.795	0.533	0.802	0.914	0.879	0.683	0.957
YOLOv3	VGG-16	0.815	0.634	0.833	0.918	0.837	0.723	0.944
CR-RFPR101	ResNeXt101-64	0.834	0.640	0.866	0.926	0.883	0.726	0.965

基于 ResNeXt-101-64×4d 网络的 Cascade R-CNN 算法 mAP 值为 81.8%，在不增加参数复杂度的前提下，提高了算法的准确率。利用线性加权的 Soft-NMS 代经典 NMS，mAP 值提高了 0.5%，较好地提高准确性。使用 RFP 代替传统特征金字塔的操作使得 CR-RFPR101 算法的 mAP 值提高了 1.1%，相比于原始 Cascade R-CNN 提高了 7.3%，有效提高了检测的精度和鲁棒性。

由表 3 可知,CR-RFPR101 算法有着显著的检测优势,本文算法与 YOLOv3、SSD、Faster R-CNN 算法相比,精确度分别提高了 3.7%、3.9%、1.9%，并且 6 种缺陷的 AP 值均获得最高值。

5 种检测算法的 P-R 曲线如图 7 所示,由图 7 可知,CR-RFPR101 算法的总体检测性能较好。

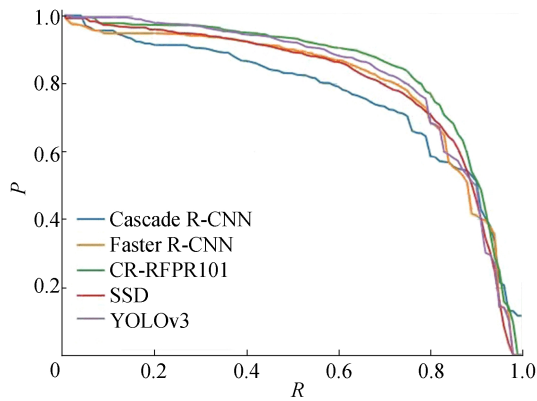




图 7 各模型的 P-R 曲线对比结果

YOLOv3、SSD、Faster RCNN、Cascade RCNN 和 C-RRFPR101 算法检测结果的混淆矩阵如图 8 所示。


通过比较混淆矩阵,可以看出,CR-RFPR101 在 6 种缺陷中的 Pc、PS、St 3 种上产生了较好的分类性能,表明所提出的 CR-RFPR101 算法的可行性和适用性。




(b) SSD



(c) Faster R-CNN



(d) Cascade R-CNN



(e) CR-RFPR101

图 8 不同模型的混淆矩阵结果

为了更加直观地比较不同算法的检测性能,本文增加了可视化实验,检测结果如图 9 所示。其中:绿色框代表实际结果;橙色框表示检

测结果。

从图 9 可以看出,CR-RFPR101 算法的检

测框与实际标签的贴合程度最高,优于其他对比缺陷检测算法。

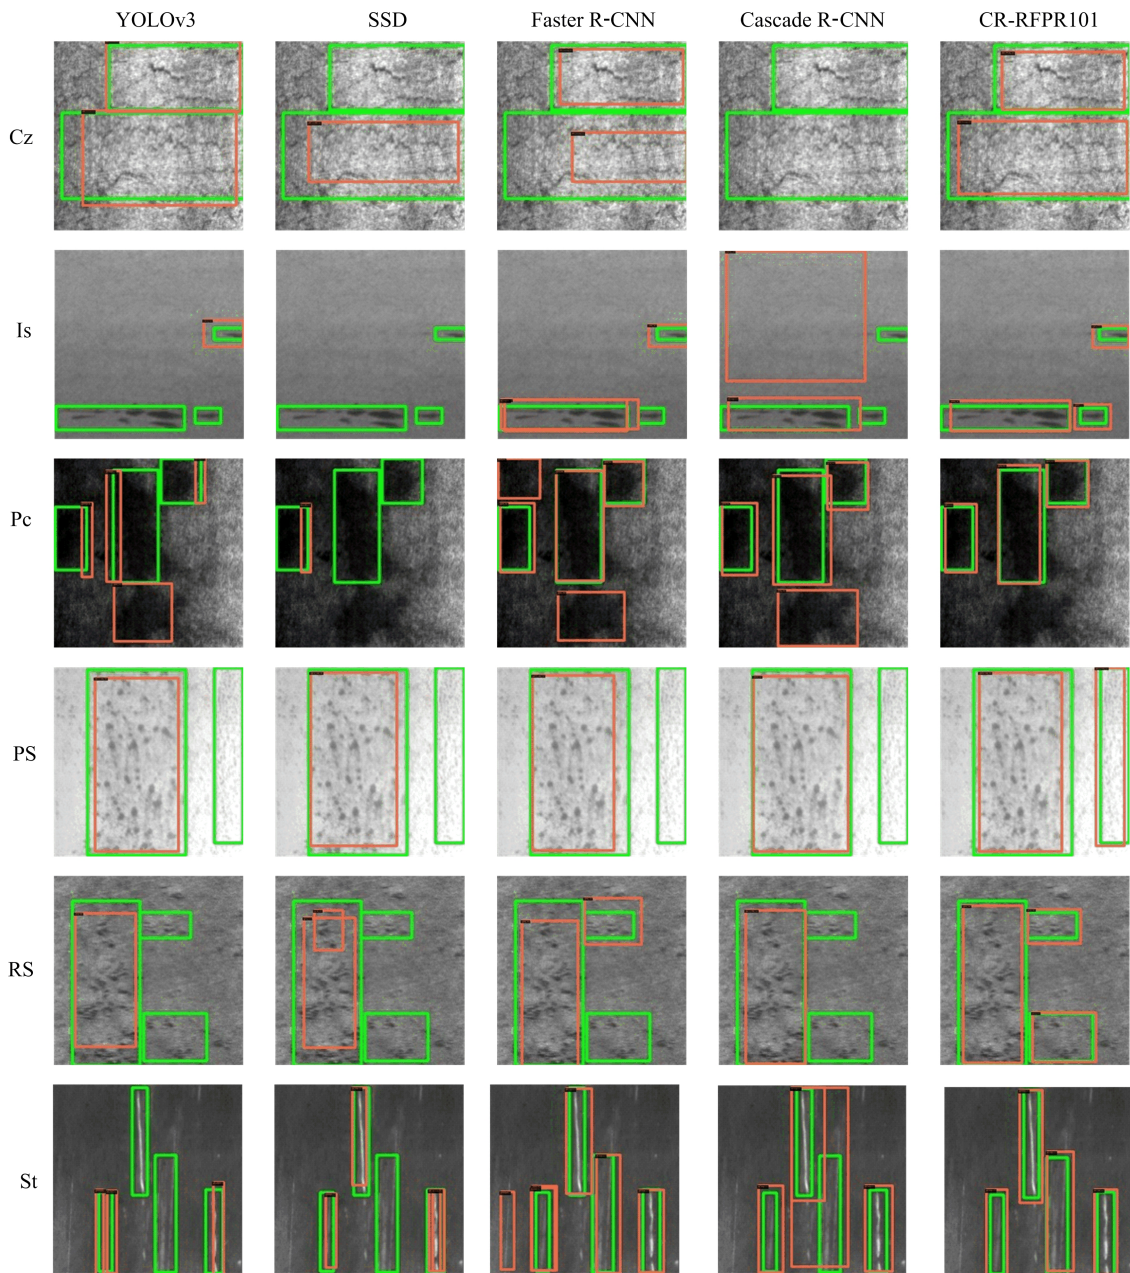


图 9 缺陷检测对比结果示例

4 结 论

本文提出了一种基于 CR-RFPR101 的目标检测算法,该算法使用 ResNeXt-101-64 × 4d 作为 Cascade R-CNN 模型的骨干网络,采用恒等映射的方式优化特征提取功能;利用递归特征金字塔代替经典特征金字塔,以反馈的方式优化主干网络,实现多尺度的目标检测;采用可切换的空洞卷积改变主干网络的卷积层,通过改变空洞率以确定适合钢板表面缺陷的感受野,提高模型的检测性能;利用

线性加权形式的 Soft-NMS 对非极大值抑制进行优化,以降低误检和漏检率,提高模型的准确率。

通过消融实验和与经典的检测算法相比较,CR-RFPR101 算法在钢板表面缺陷检测问题上具有明显的检测优势。

[参 考 文 献]

- [1] 屈尔庆,崔月姣,徐森,等. 改进的 Gabor 滤波器带钢板表面缺陷显著性检测[J]. 华中科技大学学报(自然科学版),2017,45(10):12-17.
- [2] 李少波,杨静,王铮,等. 缺陷检测技术的发展与应用研究综

- 述[J]. 自动化学报, 2020, 46(11): 2319-2336.
- [3] 李维刚, 叶欣, 赵云涛, 等. 基于改进 YOLOv3 算法的带钢表面缺陷检测[J]. 电子学报, 2020, 48(7): 1284-1292.
- [4] 杨珂, 方诚, 段黎明. 基于深度学习模型融合的铸件缺陷自动检测[J]. 仪器仪表学报, 2021, 42(11): 150-159.
- [5] 何彧, 宋克臣, 张德富, 等. 融合多层次特征的弱监督钢板表面缺陷检测算法[J]. 东北大学学报(自然科学版), 2021, 42(5): 687-692.
- [6] 于海涛, 李福龙, 刘亚姣, 等. 改进注意力机制的型钢表面微小缺陷检测方法[J]. 计算机工程与应用, 2022, 58(11): 250-259.
- [7] LIU Y, GENG J H, SU Z F, et al. Real-time classification of steel strip surface defects based on deep CNNs[C]// Proceedings of 2018 Chinese Intelligent Systems Conference. [S. l.]: Springer, 2019: 257-266.
- [8] 朱晓璐, 韩林, 邹香玲. 基于 SIFT 特征与多层 BP 神经网络的钢板缺陷检测算法[J]. 组合机床与自动化加工技术, 2017(10): 54-56, 61.
- [9] WANG H Y, ZHANG J W, TIAN Y, et al. A simple guidance template-based defect detection method for strip steel surfaces[J]. IEEE Transactions on Industrial Informatics, 2018, 15(5): 2798-2809.
- [10] NEVEN R, GOEDEME T. A multi-branch U-Net for steel surface defect type and severity segmentation[J]. Metals, 2021, 11(6): 870.
- [11] 徐镗, 朱洪锦, 范洪辉, 等. 改进的 YOLOv3 网络在钢板表面缺陷检测研究[J]. 计算机工程与应用, 2020, 56(16): 265-272.
- [12] 翁玉尚, 肖金球, 夏禹. 改进 Mask R-CNN 算法的带钢表面缺陷检测[J]. 计算机工程与应用, 2021, 57(19): 235-242.
- [13] LIU K, WANG H Y, CHEN H Y, et al. Steel surface defect detection using a new Haar-Weibull-variance model in unsupervised manner[J]. IEEE Transactions on Instrumentation and Measurement, 2017, 66(10): 2585-2596.
- [14] CAI Z W, VASCONCELOS N. Cascade r-cnn: Delving into high quality object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. [S. l.]: IEEE, 2018: 6154-6162.
- [15] QIAO S Y, CHEN L C, YUILLE A. Detectors: detecting objects with recursive feature pyramid and switchable atrous convolution[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. [S. l.]: IEEE, 2021: 10213-10224.
- [16] BODLA N, SINGH B, CHELLAPPA R, et al. Improving object detection with one line of code[EB/OL]. [2023-11-20]. <https://arXiv.org/pdf/1704.04503.pdf>.
- [17] NEUBECK A, VAN GOOL L. Efficient non-maximum suppression[C]// 18th International Conference on Pattern Recognition. [S. l.]: IEEE, 2006: 850-855.
- [18] LI Z M, PENG C, YU G, et al. Detnet: a backbone network for object detection [EB/OL]. [2023-11-20]. <https://arXiv.org/pdf/1804.06215.pdf>.
- [19] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. [S. l.]: IEEE, 2017: 2117-2125.
- [20] 赵振兵, 熊静, 李冰, 等. 基于改进 Cascade R-CNN 的典型金具及其部分缺陷检测方法[J]. 高电压技术, 2022, 48(3): 1060-1067.

(责任编辑 李 凯)

(上接第 1641 页)

[参 考 文 献]

- [1] 曹科. 精密齿轮传动误差的研究[D]. 北京: 北方工业大学, 2019.
- [2] 韩连福. 齿轮测量中心若干关键技术研究[D]. 哈尔滨: 哈尔滨工业大学, 2015.
- [3] 刘国云, 曾京, 戴焕云, 等. 考虑轴箱轴承表面波纹度的高速车辆振动特性分析[J]. 机械工程学报, 2016, 52(14): 147-156.
- [4] 邵建敏, 王伟. 表面波纹度对球轴承振动影响的模拟分析[J]. 郑州工学院学报, 1994, 15(3): 67-72.
- [5] 时博阳. 实测波纹度圆柱滚子轴承的动力学建模及波数识别方法研究[D]. 重庆: 重庆大学, 2018.
- [6] 胡凤英. 波纹度参数的研究及检测[J]. 内燃机配件, 2006(2): 38-39.
- [7] 罗太景. 齿轮表面波纹度的质量控制[J]. 机械传动, 2006, 30(1): 84-85.
- [8] 郝梦梦, 谢小秤, 孙长义. 齿面傅里叶检测与噪音分析[J]. 江西化工, 2019(2): 249-250.
- [9] GRAVEL G. Analysis of ripple on noisy gears[J]. Gear Solutions, 2013(1): 38-47.
- [10] GRAVEL G. Analysis of gear measurement to solve noise problems in gear boxes[C]// Swedish Production Symposium Lund. [S. l. : s. n.], 2016: 1-7.
- [11] REAVIE T, KOULIN G, FRAZER R C, et al. A method to quantify waviness measurement capability of a gear measurement machine[J]. Surface Topography: Metrology and Properties, 2019, 7(1): 015002.
- [12] MALBURG M, ZECCHINO M. Understanding and controlling the source of gear noise[J]. Gear Technology, 2021(8): 48-51.

(责任编辑 闫杏丽)