

DOI:10.19651/j.cnki.emt.2210754

# 基于改进 RetinaNet-GHM 算法的钢板表面缺陷检测 \*

李雪露 杨永辉 储茂祥

(辽宁科技大学电子与信息工程学院 鞍山 114051)

**摘要:** 针对传统钢板表面缺陷检测方法效果差、缺陷定位不准确等问题,提出一种基于改进 RetinaNet-GHM 的深度学习检测算法。首先,引入路径聚合特征金字塔网络融合浅层和深层语义信息,提升网络对小目标的检测效果;然后,使用 GHMC 和 GHMR 损失函数对缺陷进行分类和定位;最后,引入高斯形式的软化非极大值抑制算法,提高检测精度。实验结果表明,改进的 RetinaNet-GHM 算法的平均精度均值为 76.7%,裂纹、夹杂、斑块、麻点、压入氧化铁皮以及划痕六类缺陷的平均精度分别为 45.2%、88.2%、94.2%、86.1%、65.1% 和 87.4%。通过与其他经典算法相比,改进的 RetinaNet-GHM 算法具有较好的检测效果。

**关键词:** 目标检测;路径聚合特征金字塔网络;GHM 损失函数;软化非极大值抑制

中图分类号: TP391.41; TP751.1 文献标识码: A 国家标准学科分类代码: 520.6040

## Steel plate surface defect detection based on improved RetinaNet-GHM algorithm

Li Xuelu Yang Yonghui Chu Maoxiang

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

**Abstract:** Aiming at the problems of poor effect and inaccurate defect location of traditional steel plate surface defect detection methods, a deep learning detection algorithm based on improved RetinaNet-GHM was proposed. Firstly, the path aggregation feature pyramid network is introduced to fuse shallow and deep semantic information to improve the detection effect of the network on small targets. Then, GHMC and GHMR loss functions are used to classify and locate defects. Finally, the soft-non maximum suppression algorithm in Gaussian form is introduced to improve the detection accuracy. The experimental results show that the average accuracy of the improved RetinaNet-GHM algorithm is 76.7%, and the average accuracy of crazing, inclusion, patches, pitted surface, rolled-in\_scale and scratchs is 45.2%, 88.2%, 94.2%, 86.1%, 65.1% and 87.4% respectively. Compared with other classical algorithms, the improved RetinaNet-GHM algorithm has better detection effect.

**Keywords:** object detection; path aggregation feature pyramid network; GHM loss function; soft-non maximum suppression

## 0 引言

钢板作为工业生产和发展的基础,在汽车制造、房屋建筑等领域有着重要的应用,钢板质量直接关乎其产品的使用性能。因此钢板的质量检测很有意义<sup>[1]</sup>。

基于传统的钢板表面缺陷检测方法效果差,速度较慢。随着机器视觉的快速发展,卷积神经网络理论逐渐成熟,深度学习技术已经普遍应用于钢板表面缺陷检测中<sup>[2]</sup>。吴越等<sup>[3]</sup>提出一种改进池化方式的基于区域的快速卷积网络(faster region-based convolutional network method, Faster

RCNN)的带钢表面缺陷检测算法。Qian<sup>[4]</sup>提出一种基于 U-Net 和特征金字塔网络的算法,对钢板表面缺陷进行语义分割。李庆党等<sup>[5]</sup>提出一种优化 YOLOv3 (you only look once)骨干网络和损失函数的钢板表面缺陷检测算法。Roberts 等<sup>[6]</sup>引入 DefectSegNet 神经网络对钢材缺陷检测与分割。Wu 等<sup>[7]</sup>提出一种基于改进迁移学习检测模型和全卷积神经网络的分割模型,以实现优质检测。李钧正等<sup>[8]</sup>提出一种基于小样本的检测技术。Zhao 等<sup>[9]</sup>提出一种多尺度融合和可变形卷积网络改进的 Faster R-CNN 算法,用来检测小而复杂的缺陷目标。

收稿日期:2022-07-20

\*基金项目:国家自然科学基金(21978123)、辽宁省高等学校基本科研项目(2020LNZD06)资助

文中对 RetinaNet-GHM 算法进行改进, 以更好地实现钢板表面缺陷检测。为了加强网络对小目标特征信息的提取, 使用路径聚合特征金字塔网络 (path aggregation feature pyramid network, PAFPN)<sup>[10]</sup> 实现深层和浅层语义信息的特征融合。为了解决种类多样本不均衡问题, 使用梯度协调机制 (gradient harmonizing mechanism, GHM)<sup>[11]</sup> 系列损失函数。为了降低冗余框对网络的影响, 使用高斯形式的软化非极大值抑制 (soft-non maximum suppression, Soft-NMS)<sup>[12]</sup> 算法代替

传统非极大值抑制结构 (non-maximum suppression, NMS)<sup>[13]</sup>。

## 1 改进的 RetinaNet-GHM 算法

图 1 为改进的 RetinaNet-GHM 算法的网络结构。首先利用 ResNeXt101 网络进行特征提取。然后将提取到的特征图输入到 PAFPN 模块实现深层和浅层语义信息的特征融合。最后利用 GHM-C 和 GHM-R 损失函数实现缺陷的回归和分类。

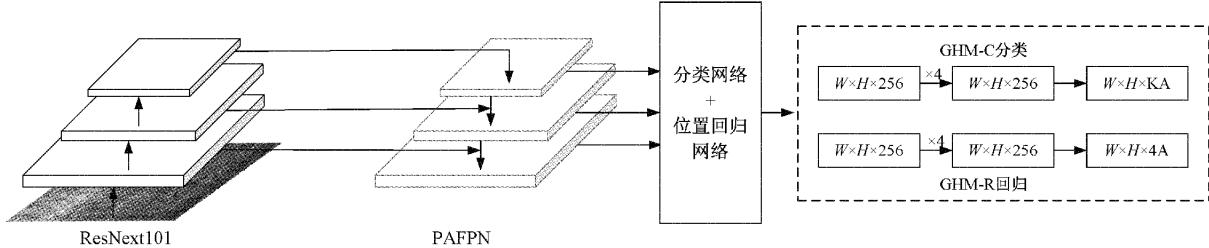


图 1 改进的 RetinaNet-GHM 网络结构

### 1.1 特征金字塔网络的改进

RetinaNet-GHM 算法使用 FPN 特征融合的方式加强网络的特征提取能力, 而 PAFPN 模块则是在 FPN 模块的基础上创建了自下而上的路径增强。图 2 为 PAFPN 的网络结构, 首先提出了一个自顶向下和自底向上的双向融合

骨干网络, 同时在最底层和最高层之间添加了一条支路, 用于缩短层之间的路径, 然后还提出了自适应特征池化模块, 用于聚合不同层之间的特征, 保证特征的完整性和多样性, 最后的全连接融合模块以得到更加准确的预测框。

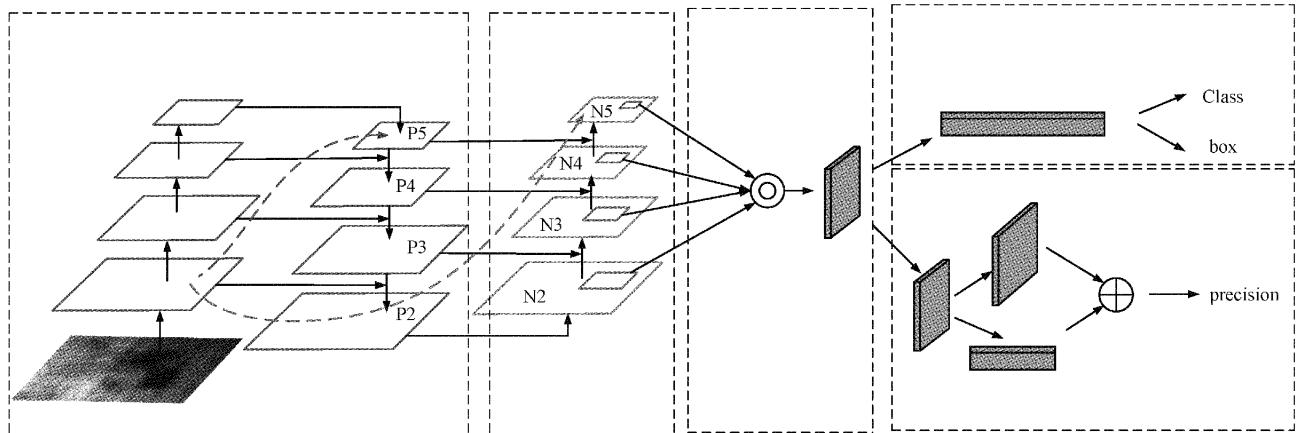


图 2 PAFPN 的网络结构

### 1.2 损失函数的改进

RetinaNet 算法提出使用焦点损失函数 Focal loss 来解决缺陷检测过程中存在的样本不均衡问题, 但是在处理特别难分类的样本时会容易出现过拟合的风险。

因此, 本文选用 GHM 损失函数来解决 Focal loss 函数存在的不足, 通过增加一定范围内置信度的样本数量来衰减损失函数, 以提高检测率。先定义一个梯度密度函数  $GD(g)$ :

$$GD(g) = \frac{1}{l(g)} \sum_{k=1}^N \delta(g_k, g) \quad (1)$$

其中,  $\delta(g_k, g)$  为样本  $k$  的梯度  $g_k$  是否在区间  $[g - \frac{\epsilon}{2}, g + \frac{\epsilon}{2}]$  内;  $l(g)$  为区间长度, 即  $\epsilon$ 。然后把每一个样本的交叉熵损失除以他们对应的梯度密度:

$$L_{GHM} = \sum_{i=1}^N \frac{CE(p_i, p_i^*)}{GD(g_i)} \quad (2)$$

其中,  $N$  为样本数量的总数,  $CE(p_i, p_i^*)$  为表示第  $i$  个样本的交叉熵损失,  $GD(g_i)$  表示第  $i$  个样本的梯度密度。

RetinaNet-GHM 模型的分类损失函数  $L_{GHM-C}$  可以定

义为:

$$L_{GHM\_C} = \sum_{i=1}^N \frac{L_{CE}(p_i, p_i^*)}{GD(g_i)} \quad (3)$$

RetinaNet-GHM 模型的回归损失函数  $L_{GHM\_R}$  可以定义为:

$$L_{GHM\_R} = \sum_{i=1}^N \frac{ASL_1(d_i)}{GD(gr_i)} \quad (4)$$

其中,  $ASL_1(d_i)$  为修正后的 Smooth L1 函数:

$$smooth_{L1}(m) = \begin{cases} 0.5m^2, & |m| < 1 \\ |m| - 0.5, & \text{其他} \end{cases} \quad (5)$$

### 1.3 非极大值抑制模块的改进

RetinaNet-GHM 算法利用 NMS 模块过滤多余候选框, 通过设置阈值, 将置信度低于阈值的锚框直接过滤掉, 降低了检测精度。

因此, 本文选用基于高斯形式的 Soft-NMS 算法代替传统的 NMS, 设置 IOU 为 0.55, 当得到置信度较低的锚框时, 不是直接滤除, 而是不断更新其置信度值后输出, 增强检测效果。基于高斯形式的 Soft-NMS 的公式如下:

$$s_j = s_j e^{-\frac{iou(M, b_j)}{\sigma}}, \forall b_j \notin D \quad (6)$$

其中, 为得分最高的框, 为待检测的框, 为最终得分。

## 2 实验结果与分析

### 2.1 实验数据集

本文选用 NEU-DET 数据集进行训练和测试, 缺陷图片为 1800 张, 共计 6 类缺陷。缺陷分别为 A(裂纹)、B(夹杂)、C(斑块)、D(麻点)、E(压入氧化铁皮)以及 F(划痕)。其中设置训练集 1440 张, 占比 80%。验证集 360 张, 占比 20%<sup>[14]</sup>。缺陷图像像素大小为 200×200, 均为灰色图像。钢板表面缺陷如图 3 所示。

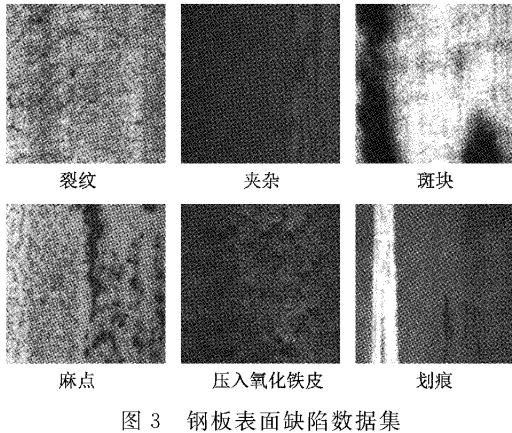


图 3 钢板表面缺陷数据集

### 2.2 实验训练及参数设置

模型在 Ubuntu 20.04 操作系统下进行训练, GPU 型号为 NVIDIA GeForce RTX 3060, CPU 型号为 Intel(R) Core(TM) i7-7800X, python 版本为 python3.7, 集成开发环境为 CUDA11.3, 深度学习框架为 pytorch, 内存为

16 G。模型训练使用 SGD 优化器优化网络参数, 改进的 RetinaNet-GHM 损失函数收敛情况如图 4 所示。

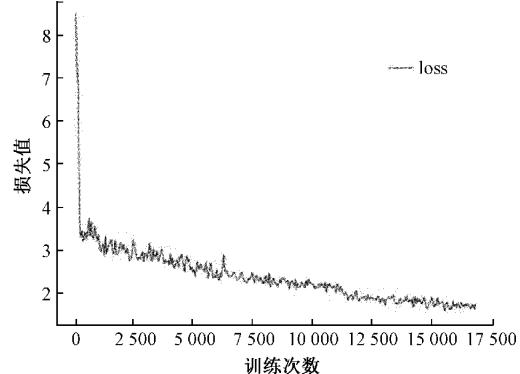


图 4 改进的 RetinaNet-GHM 损失函数收敛情况

由图 4 可知, 改进的 RetinaNet-GHM 模型的损失值随着训练迭代次数的增加而逐渐减小, 在约为 1.2 左右平稳浮动并收敛, 使得模型的预测值更接近检测目标值。

### 2.3 实验评价标准

对于钢板表面缺陷检测, 通常使用 IOU(intersection of union)来量化预测框与实际标签的贴合程度。IOU 计算原理如图 5 所示, IOU 为两个检测框的交并比, 公式如式(7)所示, IOU 的取值范围为 0~1, IOU 值越大, 两个框的重叠区域越大, 检测精度越高。

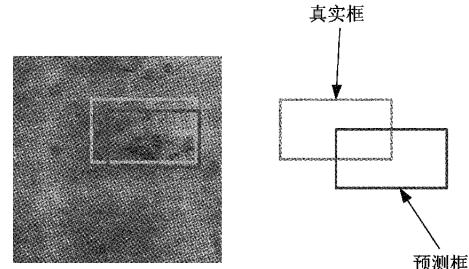


图 5 IOU 计算原理

$$IOU_{A,B} = \frac{S_A \cap S_B}{S_A \cup S_B} \quad (7)$$

选用 mAP(mean average precision)这一指标来评价改进的 RetinaNet-GHM 模型的好坏, 其中, AP(average precision)为每一类钢板表面缺陷的检测精度, mAP 则是 6 种钢板表面缺陷的平均精度<sup>[15-16]</sup>。AP 和 mAP 计算公式如下:

$$AP = \sum_n \frac{Precision}{n} \quad (8)$$

$$mAP = \frac{\sum_{v=1}^V AP}{V} \quad (9)$$

式中:  $n$  是缺陷总数目,  $V$  是缺陷类别数。

通过 TP 的数量来计算改进的 RetinaNet-GHM 模型的召回率(recall, R)和精确率(precision, P), P 和 R 的计

算公式如下:

$$P = \frac{TP}{TP + FP} \quad (10)$$

$$R = \frac{TP}{TP + FN} \quad (11)$$

其中,若将正类样本标记为 1,负类样本标记为 0,则 TP 表示将 1 预测为 1,FP 表示将 0 预测为 1,FN 表示将 1 预测为 0。

由表 1 可知,使用 GHM 损失函数的 RetinaNet 模型的 mAP 值为 73.0%,且斑块类缺陷获得了最高 AP 值,并

且没有出现梯度爆炸情况。利用 PAFFPN 模块代替传统 FPN 的操作使得模型的 mAP 值提高了 3.3%,且夹杂、麻点、压入氧化铁皮、划痕 4 类缺陷的 AP 值均有大幅提升,较好地实现了深层和浅层语义信息的特征融合,提高模型的检测性能。采用高斯形式的 Soft-NMS 滤掉多余候选框的方式使得模型的 mAP 值提高了 0.4%,并且有效提升了裂纹缺陷的检测精度,夹杂和划痕缺陷取得了最高的 AP 值,斑块、麻点和压入氧化铁皮缺陷 AP 虽不是最大值,但是均与最高值相差不多,此改进方式降低了 RetinaNet-GHM 模型的漏检率和误检率。

表 1 消融实验结果

RetinaNet	GHM	PAFFPN	Soft-NMS	A(AP)	B(AP)	C(AP)	D(AP)	E(AP)	F(AP)	mAP
✓	✓	—	—	0.434	0.799	0.944	0.864	0.621	0.737	0.730
✓	✓	✓	—	0.423	0.813	0.939	0.881	0.653	0.871	0.763
✓	✓	✓	✓	0.452	0.822	0.942	0.861	0.651	0.874	0.767

本文将改进的 RetinaNet-GHM 算法与 Faster RCNN, SSD, YOLOv3, YOLOX-S, Cascade RCNN 等

经典目标检测算法进行实验对比,实验结果如表 2 所示。

表 2 缺陷的平均检测精度

算法	Faster R-CNN	SSD	YOLOv3	YOLOX-S	Cascade R-CNN	改进的 RetinaNet-GHM
A	0.390	0.410	0.425	0.347	0.402	0.452
B	0.831	0.753	0.716	0.795	0.830	0.822
C	0.937	0.934	0.908	0.930	0.930	0.942
D	0.859	0.798	0.813	0.785	0.831	0.861
E	0.619	0.626	0.598	0.629	0.595	0.651
F	0.909	0.823	0.900	0.903	0.938	0.874

由表 2 可以看出,改进的 RetinaNet-GHM 算法检测到的裂纹、斑块、麻点和压入氧化铁皮 4 种缺陷的 AP 值均为最高,说明本文算法不仅可以提高检测精度,对于裂纹这种小目标缺陷检测效果也优于其他对比算法。

表 3 给出了 6 种不同算法对钢板表面缺陷的平均检测精度均值。与 YOLOv3 算法相比,精确度提高了 4.1%,与 YOLOX-S 算法相比,精确度值提高了 3.5%,与 SSD 算法相比,精确度提高了 4.3%,与 Faster R-CNN 算法相比,精确度高 1.0%,与 Cascade R-CNN 算法相比,精确度提高了 1.3%,改进的 RetinaNet-GHM 算法有着较高的检测性能。

为了进一步验证 RetinaNet-GHM 算法的有效性,使用 P-R 曲线作为评价标准。不同算法的 P-R 曲线如图 6 所示,改进 RetinaNet-GHM 的算法的 P-R 曲线在最外边缘,P-R 围成的面积最大,该算法可以有效解决钢板表面缺陷检测问题。

图 7 为钢板表面缺陷可视化检测结果。由图 7 可以看出,使用本文检测的斑块、麻点、夹杂 3 种缺陷的检测框与实际框的重合度高,并且漏检和误检现象明显低于其他

表 3 不同算法性能对比结果

方法	Backbone	mAP
Faster R-CNN	VGG-16	0.757
SSD	VGG-16	0.724
YOLOv3	Darknet-53	0.726
YOLOX-S	CSPDarknet	0.732
Cascade R-CNN	ResNet50	0.754
改进的 RetinaNet-GHM	ResNeXt101	0.767

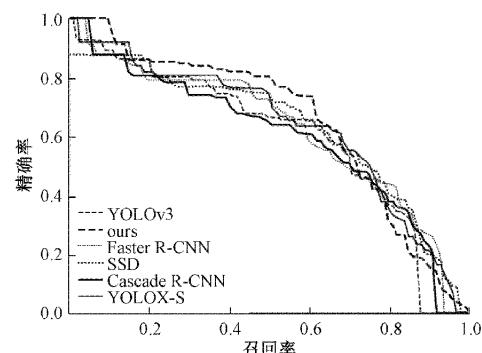


图 6 不同算法的 P-R 曲线

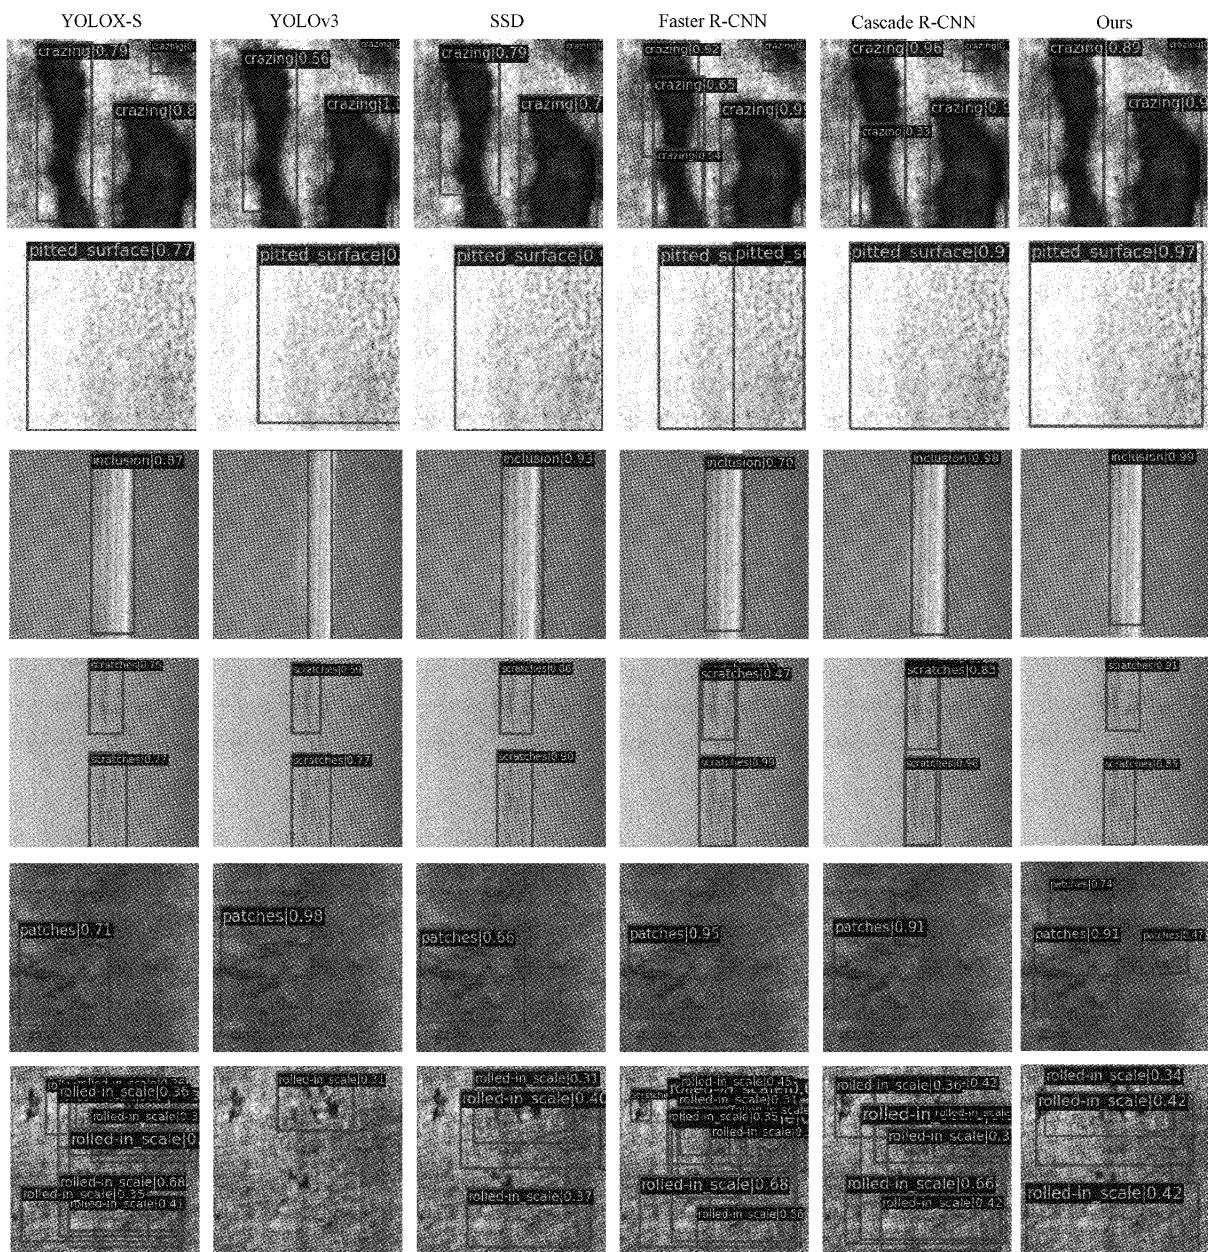


图 7 缺陷检测对比结果示例

算法,改进的 RetinaNet-GHM 模型的回归定位效果较好。

### 3 结 论

针对目前钢板表面缺陷检测存在的问题,提出了一种基于改进 RetinaNet-GHM 的钢板表面缺陷检测算法。通过实验证明,提出使用 PAFPN 代替 FPN,使用 GHM 损失函数,引入高斯形式 Soft-NMS 的三个机制均提高了算法的检测精度,检测 mAP 值较原始算法提高了 3.7%。与 YOLOX-S, YOLOv3, SSD, Faster R-CNN, Cascade R-CNN 等经典算法相比,改进的 RetinaNet-GHM 算法更适用于钢板表面缺陷检测。

### 参考文献

- [1] 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.
- [2] 何彧,宋克臣,张德富,等.融合多层级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.
- [3] 吴越,杨延竹,苏雪龙,等.基于 Faster R-CNN 的钢板表面缺陷检测方法[J].东华大学学报(自然科学版),2021,47(3):84-89.
- [4] QIAN K. Automated detection of steel defects via machine learning based on real-time semantic

- segmentation[C]. Proceedings of the 3rd International Conference on Video and Image Processing, 2019; 42-46, DOI:10.1145/3376067.3376113.
- [5] 李庆党,李铁林.基于改进 YOLOv3 算法的钢板缺陷检测[J].电子测量技术,2021,44(2):104-108.
- [6] ROBERTS G, HAILE S Y, SAINJU R, et al. Deep learning for semantic segmentation of defects in advanced STEM images of steels [J]. Scientific Reports, 2019, 9(1): 1-12.
- [7] WU H, LYU Q Q. Hot-rolled steel strip surface inspection based on transfer learning model [J]. Journal of Sensors, 2021, 2021, DOI: 10.1155/2021/6637252.
- [8] 李钧正,殷子玉,乐心怡.基于小样本学习的钢板表面缺陷检测技术[J].航空科学技术,2021,32(6):65-70.
- [9] ZHAO W D, CHEN F, HUANG H C, et al. A new steel defect detection algorithm based on deep learning[J]. Computational Intelligence and Neuroscience, 2021, 2021, DOI: 10.1155/2021/5592878.
- [10] LIU S, QI L, QIN H F, et al. Path aggregation network for instance segmentation[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018:8759-8768.
- [11] LI B Y, LIU Y, WANG X G. Gradient harmonized single-stage detector[C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33(1): 8577-8584.
- [12] BODLA N, SINGH B, CHELLAPPA R, et al. Improving object detection with one line of code[J]. ArXiv Preprint, 2017, ArXiv:1704.04503.
- [13] NEUBECK A, VAN GOOL L. Efficient non-maximum suppression [C]. 18th International Conference on Pattern Recognition(ICPR'06), IEEE, 2006, 3: 850-855, DOI: 10.1109/ICPR.2006.479.
- [14] 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.
- [15] 李衍照,于镭,田金文.基于改进 YOLOv5 的金属焊缝缺陷检测[J/OL].电子测量技术:1-6.
- [16] HE Y, SONG K, MENG Q, et al. An end-to-end steel surface defect detection approach via fusing multiple hierarchical features[J]. IEEE Transactions on Instrumentation and Measurement, 2019, 69(4): 1493-1504.

### 作者简介

李雪露,硕士研究生,主要研究方向为图像处理、模式识别。

E-mail:lxl382636745@163.com

杨永辉(通信作者),教授,博士,博士生导师,主要研究方向为模式识别与智能控制。

E-mail:yangyh2636688@163.com

储茂祥,教授,博士,博士生导师,主要研究方向为模式识别与智能控制。

E-mail:chu52\_2004@163.com