

DOI: 10.7672/sgjs2024210011

# 基于YOLOv5的钢结构节点损伤检测研究\*

韩铭

(中国地震局工程力学研究所,黑龙江 哈尔滨 150086)

**[摘要]** 以钢结构节点损伤检测为出发点,针对算法在个人困难数据集上的优化问题,使用预训练权重,通过分析训练过程中的损失趋势评估合适的训练周期。选择CBAM注意力机制提升迁移学习的效率和性能,使用AdamW优化器加快模型收敛速度,改善数据集的划分策略以展现模型真实性能,提高模型的鲁棒性,防止过拟合。根据先进算法理论优化了模型损失函数,提升模型在个人数据集上的精确率和召回率。针对问题复杂度与算法复杂度匹配性进行试验,选择最适合个人数据集的YOLOv5n6模型,最终优化出适合在现实场景中应用的钢结构节点损伤检测模型权重。

**[关键词]** 钢结构;节点;损伤;检测;深度学习

**[中图分类号]** TU391

**[文献标识码]** A

**[文章编号]** 2097-0897(2024)21-0011-06

## Research on Damage Detection of Steel Structure Joints Based on YOLOv5

HAN Ming

(Institute of Engineering Mechanics, China Earthquake Administration, Harbin, Heilongjiang 150086, China)

**Abstract:** Taking steel structure joints damage detection as the starting point, for the optimization problem of the algorithm on personal difficult datasets, using pre-training weights, evaluating the appropriate training period by analyzing the loss trend during the training process, selecting the CBAM attention mechanism to improve the efficiency and performance of the migration learning, using the AdamW optimizer to accelerate the convergence speed of the model, improving the dataset partitioning strategy to show the real performance of the model, and improve the robustness of the model to prevent overfitting. The model loss function is optimized according to the theory of advanced algorithms to improve the accuracy and recall of the model on the personal dataset. The tests were conducted for the problem of the matching between problem complexity and algorithm complexity, select the YOLOv5n6 model that is most suitable for the personal dataset, and ultimately optimize the model weights of steel structure joints damage detection, which is suitable to be applied in the real-world scenarios.

**Keywords:** steel structures; joints; damage; detection; deep learning

### 0 引言

大跨空间结构由于其体量大且多作为人流密集的场所,在地震作用下发生破坏将造成严重的经济损失、人员伤亡和社会影响,如2013年芦山地震造成典型的大跨空间结构芦山县体育馆、芦山县中学体育馆和宝兴中学体育馆罩棚结构发生了不同程度的破坏,震后结构损伤评估和修复工作耗

费大量人力、物力和财力。

由于大跨空间结构破坏形式具有复杂化和多样化的特点<sup>[1-3]</sup>,地震后对其进行损伤检测较困难。目前损伤检测手段主要包括视觉检查、超声波测量等,在实际应用中操作复杂、耗时长且对专业人员的依赖性高。近年来,深度学习技术迅速发展,促进了不同学科领域创新与发展,尤其是图像识别类模型在结构损伤检测领域呈现出了应用潜力,通过训练深度卷积神经网络(convolutional neural networks, CNN)识别并定位图像中的损伤区域或构件,可提高检测准确性和效率,以通过无人机进行

\* 黑龙江省自然科学基金(JQ2022E006);中国地震局工程力学研究所科研基金(2021B01,2021EEEEVL0308)

[作者简介] 韩铭,硕士,E-mail:3432714399@qq.com

[收稿日期] 2024-06-16

大跨空间结构震后损伤情况评估,同时保证了评估人员自身安全。

已有学者在损伤检测方面进行了深度学习相关研究,如卢树杰等<sup>[4]</sup>利用无人机拍照和计算机视觉技术,实现了对钢结构锈蚀的自动检测;Wang等<sup>[5]</sup>使用 CNN 网络识别螺栓松动状态,并通过霍夫变换估计旋转角度;Zhang 等<sup>[6]</sup>使用螺栓松动图像训练 Fast R-CNN 模型,以检测钢结构中的松动螺栓;胡欣等<sup>[7]</sup>基于改进的 YOLOv5 对螺纹钢表面缺陷进行了检测;Cha 等<sup>[8]</sup>使用 Faster R-CNN 模型对混凝土裂缝、两级(中等和高度)钢腐蚀、螺栓腐蚀和钢分层数据进行了训练和检测。

本研究以钢结构节点损伤检测为目标,在目标检测算法 YOLOv5 的基础上,针对个人数据集进行模型调整,对 YOLOv5 算法关键部分与模型设计进行研究,优化适合个人困难数据集的最优模型,为深度学习在交叉领域中的应用提供参考。

## 1 数据集准备

钢结构节点在地震作用下的破坏形式主要包括:①焊缝因承受过大剪力、扭矩产生裂纹或破坏;②螺栓连接处或薄板连接节点因承受过大剪力发生剪切破坏或断裂;③节点连接处因材料应力超过其弹性极限发生塑性变形,如图 1 所示。为方便后续研究,简单地将节点分为完好节点和损伤节点,进行震后钢结构损伤等级评估,需提取无人机拍摄图像中的所有节点,识别并定位其中的损伤节点。

钢结构节点损伤检测问题适合利用深度学习计算机视觉领域的目标检测算法解决,难点在于钢结构节点数量多且分布密集,目前开源算法大部分是在 COCO 数据集上训练验证的,为优化出在下游领域性能较好的模型,须有针对性地对个人问题和数据集进行算法调整。

数据集中的图像来自 2013 年芦山 7.0 级地震中钢结构损伤照片和使用相机、无人机拍摄的哈尔滨地区钢结构照片与视频(见图 2)。对数据集进行进一步筛选,保证数据的多样性,剔除相似度高的图像,将图像适当裁剪保留关键部分。共整理出 1 815 张图像,其中含有损伤节点的图像约 100 张。将数据集以 4:1 的比例划分为训练集与验证集,初始划分方式为随机划分。

## 2 YOLOv5 算法

目标检测卷积神经网络主流算法有两类,其中,一阶段算法以 YOLOv5 为代表,无须预选区域,直接输出物体类别概率和位置坐标值,经过非极大值抑制后输出预测结果,有着更快的检测速度;二




图 1 受到破坏的钢结构节点

Fig. 1 Damaged steel structure joints



图 2 待检测的钢结构节点

Fig. 2 Steel structure joints waiting for detection

阶段算法以 Faster R-CNN 为代表<sup>[9]</sup>,首先从图像中生成预选区,然后从预选区生成最终的物体边框,该算法精度较高,但训练与推理速度较慢。在实际工程中,YOLO 算法以其检测速度快、体积小、方便部署等优异性能备受青睐<sup>[10]</sup>,技术方面相对成熟,因此本研究以 YOLOv5 为基础进行优化。

首先将图像自适应缩放至长边相等,然后进行图像增强处理,包括随机透视变换、平移、剪切、旋转、缩放等,图像内节点标签信息随着数据增强操作同等变换。图像输入模型前向传播得到不同深度的 3 层特征图,在 3 层特征图上分别检测大、中、小类目标,浅层特征图预测小目标,深层特征图预测大目标。检测头部分通过卷积操作控制输出维度,输出每个位置上所有类别的预测分数、置信度、预测框相对于基本框中心点的偏移量、预测框相对

于基本框高宽的缩放系数。损失函数有 3 项,即采用 BCE loss 的分类损失和置信度损失<sup>[11]</sup>,采用 CIoU 的定位损失<sup>[12]</sup>,其中分类损失和定位损失仅考虑正样本的损失,置信度损失考虑所有样本的损失。对大、中、小类目标依据检测难度设置权重系数,计算 1 个批量图像的损失后,依据梯度下降法进行损失的反向传播,更新网络模型权重,其中涉及学习率调整、权重衰减等优化方法,依据模型在验证集上的精确率、召回率、平均精度(mAP)等指标加权计算得到 1 个拟合度,根据拟合度高低保存性能最好的模型。推理时,将检测头输出的预测框进行非极大值抑制,取出类别分数最大者,综合考虑预测框类别分数和置信度,如果大于指定阈值则保留,进行类别间的非极大值抑制,去除对于同一目标可能的重复预测框,得到图像的最终预测结果。

### 3 模型训练优化

因数据集分为完好节点和损伤节点,损伤节点数据显示难以获得,2 类数据分布不均衡,因此本研究仅完成钢结构节点损伤检测的第 1 步,在密集困难场景下检测出图像中的所有完好节点和损伤节点。将完好节点和损伤节点分开的任务属于细粒度分类问题,有待进一步研究,本研究旨在探索深度学习在钢结构节点损伤检测过程中应用的理论方法,为后续研究提供参考。

#### 3.1 数据集与训练周期

在交叉领域应用深度学习时,不易获取数据,需利用有限的数据集训练出性能可接受的模型。另外,在模型训练过程中,损失值一直下降,需控制合适的训练周期量,保证模型训练充分不至于欠拟合,同时尽量避免模型过拟合降低泛化能力。

为解决上述问题,需从模型训练过程中的损失值入手进行分析,训练集损失值除了用于求解反向梯度和了解模型训练过程中的下降趋势外,还可揭示模型性能存在的瓶颈,在模型优化过程中,对模型应采用的优化策略具有一定指导意义。随着训练的进行,如果训练集和测试集损失值均下降,说明模型还在有效学习;如果训练集损失值下降,但测试集损失值上升,说明模型越来越拟合训练集,泛化能力越来越差;如果训练集损失值继续下降,但测试集损失值停止下降,认为该模型已处于过拟合状态,即可停止训练。

开源模型应用到下游任务时,可使用官方权重在个人数据集上进行微调,微调过程中可选择冻结指定网络层权重,也可使用配置文件从头训练。针对个人数据集,使用 YOLOv5s 进行初步测试,设置 4

组试验,分别为使用配置文件+300epochs(试验 1)、使用预训练权重+100epochs(试验 2)、使用预训练权重+150epochs(试验 3)、使用预训练权重+冻结主结构(backbone)权重+150epochs(试验 4),patience 均设为 50epochs,其中 1 个 epoch 表示整个训练数据集被神经网络完整地通过 1 次,patience 表示模型性能不再提升的观察周期数,训练过程中损失值下降曲线如图 3 所示。




图 3 损失值下降曲线

Fig. 3 Loss value decline curves

对比使用预训练权重(试验 2)与从头训练(试验 1)的数据差异,使用预训练权重时精确率、召回率、平均精度明显更高,收敛速度更快,因此对在公开大数据集上训练过的权重进行微调是有必要的。由图 3 可知,训练集损失值持续下降,验证集损失值在 60epochs 后存在微上升趋势,最终收敛时训练集损失值低于验证集损失值,说明出现了一定的过拟合现象;收敛损失接近,说明对于钢结构节点损伤检测来说,数据集规模是足够的。权衡考虑,确定之后所有训练均以 epoch = 120, patience = 15 为基准。

#### 3.2 注意力机制

注意力机制是深度学习领域广泛应用的技术,通过关注输入特征图的重要部分,并分配有限的信

息处理资源给重要部分,降低算法对噪声的敏感性,增强模型的泛化能力。通常的实现方式为训练模型根据输入特征图的不同部分赋予其不同的权重,以便更集中地关注重要信息。算法开发者通常在公开的有挑战性数据集上验证算法性能,这需要算法能够从图像中提取复杂的语义信息,这样的模型应用到交叉领域时,检测难度大幅度降低,会导致部分参数和网络结构冗余,因此微调时可使用注意力机制加速收敛和优化模型。

算法精度与算法本身和数据集均有关,添加注意力机制不一定提高精度,如果模型欠拟合,注意力机制可提升算法性能,但可能造成精确率上升、召回率下降。注意力机制的添加位置和个数需要不断实践,建议加在提取高级特征的 backbone 之后。

使用 SE, CBAM, NAM 注意力机制与原版模型 Initial 进行对比试验<sup>[13-15]</sup>,采用热力图的形式展现预测特征图中类别分数、置信度分数对输入图像各位置梯度的影响,即模型从图像中提取高级语义信息,有助于理解模型的决策依据。将图 2 作为原始图像,观察添加不同注意力机制前后热力图的变化(见图 4),热力图颜色越亮表明此处梯度越大,对模型预测结果起着更重要的作用。由图 4 可知,注意力机制可帮助模型更加关注图像中待检测节点部分,其中添加 CBAM 注意力机制效果最好。

### 3.3 损失函数

对于钢结构节点损伤检测而言,检测目标密集,人眼辨别费时费力,精确的定位框有助于研究人员进行节点个体之间的区分,完成震后结构损伤状态的判断。在整体算法中,损失函数决定了模型优化方向,是深度学习优化过程中最需要注意的环节,对目标的精确定位起着关键作用。YOLOv5 中计算了 3 类损失,其中类别损失和置信度损失采用 BCE 交叉熵损失函数计算,预测框的定位损失采用 CIoU 损失函数计算,随着技术的进步,有更好的算法值得尝试。

IoU 函数用于度量目标检测任务中预测框与真实框的重叠程度,当边界框之间未重叠时,反向传播的梯度会消失。DIoU 函数将惩罚项定义为中心点间距离的归一化长度,CIoU 函数在 DIoU 函数的基础上增加了对纵横比一致性的考虑,EIoU 函数在 DIoU 函数的基础上加大了对距离度量的惩罚力度, $\alpha$ CIoU 函数基于 CIoU 进行推广,通过  $\alpha$  指数的调整,可增强算法在小型数据集上的鲁棒性。

以 YOLOv5 默认的 CIoU 为对照组,分析不同损

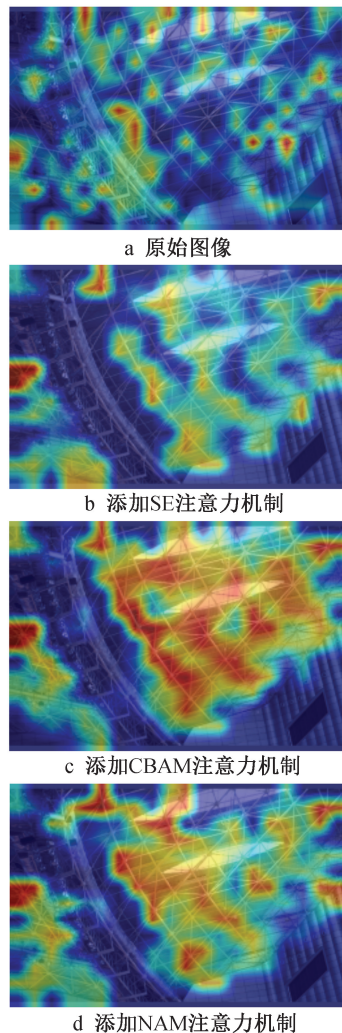


图 4 不同注意力机制下检测节点热力图

Fig. 4 Detection of joints heat maps with different attention mechanisms

伤函数训练结果,如表 1 所示。由表 1 可知,从精确率和召回率上看,损失函数优化后算法性能得到提升,这与添加注意力机制和改动优化器相比提升效果更明显,其中 EIoU 表现最好,相对于 CIoU 来说,精确率提升了 6.66%,召回率提升了 6.54%,置信度 0.5 下平均精度提升了 6.14%。综上所述,在损失函数方面进行技术更替是有价值的,后续试验将在此基础上进行。

表 1 损失函数训练结果

Table 1 Loss function training results

损失函数	停止周期	精确率	召回率	置信度 0.5 下平均精度	置信度 0.5~0.95 下平均精度
CIoU	46	0.721	0.810	0.782	0.429
EIoU	66	0.769	0.863	0.830	0.439
$\alpha$ CIoU	82	0.752	0.837	0.814	0.432
Focal	67	0.755	0.859	0.820	0.437

### 3.4 模型复杂度

在深度学习实践中,不能一味地追求网络深度与

宽度,模型复杂度应与问题复杂度相匹配,相对于要解决的问题,模型过于简单,推理性能不稳定;模型过于复杂,容易过拟合,泛化能力差。YOLOv5 针对 3 个检测层(P3,P4,P5)提供了 n,s,m,l,x 模型的配置文件和预训练权重,图像尺寸为 640 像素×640 像素,下采样倍率为 32;YOLOv5 针对 4 个检测层(P3,P4,P5,P6)提供了 n6,s6,m6,l6,x6+TTA 模型的配置文件和预训练权重,图像尺寸为 1 280 像素×1 280 像素,下采样倍率为 64。n,s,m,l,x 模型体量由小到大,之间的区别在于 C3 模块堆叠数量不同和每层网络用于提取特征的神经元个数不同。4 个检测层是在 FPN 和 PAN 结构中增加 1 层特征融合计算结构,同时考虑检测头处特征图大小的一致性,输入端图像大小扩大 2 倍。

对上述模型从简单至复杂进行逐步试验,结果如表 2 所示。由表 2 可知,综合精确率、召回率、平均精度来看,3 个检测层的模型性能优劣顺序为 YOLOv5l,YOLOv5m,YOLOv5s,YOLOv5n,基本满足模型越大越复杂,拟合能力越强的原则;YOLOv5l 模型精确率达到了 0.811,召回率达到了 0.857,置信度 0.5 下平均精度达到了 0.855,性能最好,不过从模型体量上看,该模型体量大,推理慢,不适合后续部署应用,因此未进行更大模型 YOLOv5x 试验。

表 2 模型复杂度试验结果

Table 2 Model complexity test results

模型	精确率	召回率	置信度 0.5 下平均精度	置信度 0.5~0.95 下平均精度
YOLOv5n	0.741	0.810	0.782	0.419
YOLOv5s	0.769	0.863	0.830	0.439
YOLOv5m	0.776	0.854	0.831	0.423
YOLOv5l	0.811	0.857	0.855	0.442
YOLOv5n6	0.885	0.896	0.895	0.440
YOLOv5s6	0.895	0.798	0.829	0.453

4 个检测层的 YOLOv5n6,YOLOv5s6 模型输入图像尺寸为 1 280 像素×1 280 像素,与个人数据集原始图像大小更接近,数据读取至输入端时因缩放导致的信息损失更少。YOLOv5n6,YOLOv5s6 模型下采样倍率为 64,在 4 个检测层进行检测,相较于同等大小的 YOLOv5n,YOLOv5s 模型具有先天性的优势,因此大部分指标较高。由表 2 可知,YOLOv5s6 模型体量中等,精确率最高,召回率最低,展现了精确率与召回率互相冲突的原理,表明模型复杂化倾向于提升精确率而非召回率,这与钢结构节点损伤检测重视召回率的任务理念不符,因此同样放弃 YOLOv5s6 模型,并不再进行后续更复杂模型的相关试验;与 YOLOv5m,YOLOv5s,YOLOv5n 模型相比,YOLOv5n6 模型表现

更好,因此采用 YOLOv5n6 模型作为适合个人数据集的最优模型结构。

#### 4 模型应用

使用 AdamW 优化器在预训练权重的基础上进行迁移训练,最终优化出适合在现实场景中应用的钢结构节点损伤检测模型权重,模型精确率达 0.885,召回率达 0.886,平均精度达 0.895,在实际应用中除去极小目标外,可实现钢结构节点的全面高效检测。

模型训练完成后,将权重文件进行处理可部署至移动端,支持视频和图像格式的目标检测,以矩形框的形式定位图像中的节点,给出目标的类别和置信度分数,同时可统计检测到的目标数量,帮助工作人员在震后快速定位钢结构中的完好节点和损伤节点,节省人力和时间成本,保障检测人员的自身安全。YOLOv5n6 模型检测结果如图 5 所示,由图 5 可知,该模型检测效果较好,在钢结构节点损伤检测任务中具有较高的应用价值。




图 5 YOLOv5n6 模型检测结果

Fig. 5 YOLOv5n6 model detection results

#### 5 结语

在灾后抢险救援和重建工作中,判断建筑物受损情况是关键且重要的,对于大跨空间结构,其损伤情况更加复杂,评估困难更大。近年来,深度学习技术在结构损伤方面展现出了应用前景,通过图像识别可快速、准确地了解大跨空间结构损伤情况和程度,提高了损伤检测的准确性和效率,为震后结构损伤评定提供了决策支持。

针对大跨空间结构震后损伤检测问题,本研究重点展示了深度学习目标检测应用于交叉领域时的算法优化,旨在探索可在实际工程中使用的模型优化路径,提高构件损伤自动化检测与评估效率,以密集条件下钢结构损伤节点检测为切入点,使用目标检测 YOLOv5 算法在困难数据集上进行模型优化,为模型的前沿训练与应用提供实践经验,最终给出适用于钢结构节点损伤检测的最优模型。

由于数据集中完好节点与损伤节点数量不平衡,目前模型仅能初步实现将场景中的所有钢结构节点进行提取,将损伤节点分离定位的任务需收集

更多数据后进一步研究。

### 参考文献:

- [ 1 ] 翟雷,李文涛,王永生,等. 大跨度钢结构空间张弦桁架施工全过程监测与分析[J]. 施工技术(中英文), 2022, 51(14): 77-82.  
ZHAI L, LI W T, WANG Y S, et al. Monitoring and analysis of the whole construction process of long-span steel structure spatial tensioned truss[J]. Construction technology, 2022, 51(14): 77-82.
- [ 2 ] 符涛,赵东拂,刘育民. 钢结构厂房火灾后安全性鉴定[J]. 施工技术(中英文), 2024, 53(9): 79-83.  
FU Y, ZHAO D F, LIU Y M. Safety evaluation of steel structure plant after fire [J]. Construction technology, 2024, 53(9): 79-83.
- [ 3 ] 汤东婴,魏晓斌,孙正华,等. 空间钢桁架结构卸载施工模拟及监测技术应用研究[J]. 施工技术(中英文), 2023, 52(14): 17-22.  
TANG D Y, WEI X B, SUN Z H, et al. Research on application of unloading construction simulation and monitoring technology for space steel truss structure[J]. Construction technology, 2023, 52(14): 17-22.
- [ 4 ] 卢树杰,陈庆诚,文祥,等. 基于无人机的钢结构锈蚀视觉检测[J]. 工业控制计算机, 2019, 32(7): 79-81, 87.  
LU S J, CAI Q C, WANG X, et al. Visual inspection of steel structure corrosion based on UAV [J]. Industrial control computer, 2019, 32(7): 79-81, 87.
- [ 5 ] WANG C Y, WANG N, HAO S C, et al. Design of a new vision-based method for the bolts looseness detection in flange connections [J]. IEEE transactions on industrial electronics, 2020(2): 1366-1375.
- [ 6 ] ZHANG Y, SUN X W, LOH K J, et al. Autonomous bolt loosening detection using deep learning [J]. Structural health monitoring, 2020(19): 105-122.
- [ 7 ] 胡欣,周运强,肖剑,等. 基于改进 YOLOv5 的螺纹钢表面缺陷检测[J]. 图学学报, 2023, 44(3): 427-437.  
HU X, ZHOU Y Q, XIAO J, et al. Surface defect detection of threaded steel based on improved YOLOv5 [J]. Journal of graphics, 2023, 44(3): 427-437.
- [ 8 ] CHA Y J, CHOI W, SUH S M, et al. Autonomous structural visual inspection using region-based deep learning for detecting multiple damage types [J]. Computer-aided civil and infrastructure engineering, 2018, 33(4): 731-747.
- [ 9 ] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. IEEE transactions on pattern analysis and machine intelligence, 2017, 39(6): 1137-1149.
- [ 10 ] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C]//IEEE Conference on Computer Vision and Pattern Recognition, 2016.
- [ 11 ] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE transactions on pattern analysis and machine intelligence, 2015, 37(9): 1904-1916.
- [ 12 ] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression [C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2020.
- [ 13 ] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks [J]. IEEE transactions on pattern analysis and machine intelligence, 2020, 42(8): 2011-2023.
- [ 14 ] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C]//European conference on computer vision, 2018.
- [ 15 ] LIU Y C, SHAO Z R, TENG Y Y, et al. NAM: Normalization-based attention module [C]//35th Conference on Neural Information Processing Systems, 2021.
- (上接第 10 页)
- [ 12 ] 郑欣悦. 基于深度学习的少样本图像分类方法[D]. 北京: 中国科学院大学(中国科学院国家空间科学中心), 2019.  
ZHENG X Y. A few sample image classification method based on deep learning[D]. Beijing: University of Chinese Academy of Sciences (National Space Science Center, CAS), 2019.
- [ 13 ] 卢依宏,蔡坚勇,郑华,等. 基于深度学习的少样本研究综述[J]. 电讯技术, 2021, 61(1): 125-130.  
LU Y H, CAI J Y, ZHENG H, et al. A review of small sample research based on deep learning [J]. Telecommunications engineering, 2021, 61(1): 125-130.
- [ 14 ] 徐佳琦. 基于边缘提取与 VGG16 深度卷积神经网络的混凝土裂缝识别方法研究[J]. 施工技术, 2023, 52(9): 11-15.  
XU J Q. Concrete crack recognition method based on edge extraction and VGG16 deep convolutional neural network [J]. Construction technology, 2023, 52(9): 11-15.
- [ 15 ] 高友文,周本君,胡晓飞. 基于数据增强的卷积神经网络图像识别研究[J]. 计算机技术与发展, 2018, 28(8): 62-65.  
GAO Y W, ZHOU B J, HU X F. Research on convolutional neural network image recognition based on data enhancement[J]. Computer technology and development, 2018, 28(8): 62-65.
- [ 16 ] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE transactions on pattern analysis and machine intelligence, 2017, 39(6): 1137-1149.
- [ 17 ] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C]//IEEE Conference on Computer Vision and Pattern Recognition, 2016.
- [ 18 ] ROMAN S, WEIMIN W, TATIANA G. Weighted boxes fusion: Ensembling boxes from different object detection models [J]. Image and vision computing, 2021, 107: 104117.
- [ 19 ] 陈志强,杨霞,陈小杰. YOLO 与 SAHI 模型在建筑外立面表面损伤检测中的协同应用[J]. 施工技术, 2022, 51(24): 114-119.  
CHEN Z Q, YANG X, CHEN X J. Collaboration application of YOLO and SAHI models in the detection of apparent damage of building facades [J]. Construction technology, 2022, 51(24): 114-119.