

doi:10.6041/j.issn.1000-1298.2023.03.040

# 基于 YOLO v5 – OBB 与 CT 的浸种玉米胚乳裂纹检测

宋怀波<sup>1,2</sup> 焦义涛<sup>1,2</sup> 华志新<sup>1,2</sup> 李 嵘<sup>1,2</sup> 许兴时<sup>1,2</sup>

(1. 西北农林科技大学机械与电子工程学院, 陕西杨凌 712100;

2. 农业农村部农业物联网重点实验室, 陕西杨凌 712100)

**摘要:** 浸种是玉米生产中重要的播前增种技术, 对浸种过程中裂纹的高效检测是分析玉米胚乳裂纹变化规律的基础, 是优良品种性状选育的关键之一, 尚存在内部胚乳裂纹不可见、自动化检测程度不高等困难。基于 CT 扫描技术, 在 YOLO v5n 检测网络的基础上, 设计了 YOLO v5 – OBB 旋转目标检测网络, 其中 OBB 为有向目标边框, 该网络使用旋转矩形框代替普通矩形框, 并在 Backbone 部分加入位置注意力模块(CA), 同时采用倾斜非极大值抑制算法( Skew – NMS) 进行非极大值抑制得到最终预测框, 以此实现长宽比大、方向不一的玉米胚乳裂纹检测。经过 300 次迭代训练, 模型在测试集上的精确率  $P$  为 94.2%, 召回率  $R$  为 81.7%, 平均精度(AP) 为 88.2%, 模型内存占用量为 4.21 MB, 单幅图像平均检测时间为 0.01 s, 与 SASM、S<sup>2</sup>A – Net 和 ReDet 旋转目标检测网络相比, AP 分别提高 15.0、16.9、7.0 个百分点, 单幅图像平均检测时间分别减少 0.19、0.22、0.46 s, 同时 YOLO v5 – OBB 模型内存占用量分别为 SASM、S<sup>2</sup>A – Net 和 ReDet 模型的 1.50%、1.43% 和 1.73%, 与采用水平矩形框标注的 YOLO v5 网络相比, AP 提高 0.6 个百分点, 模型大小减小 0.19 MB, 单幅图像平均检测时间不变, 两者均为 0.01 s。将 YOLO v5 – OBB 网络获取裂纹目标框坐标信息后得到的裂纹长度与在 DragonflyEZ 软件中得到的裂纹真实长度相比, 两者绝对误差为 0.04 mm, 相对误差为 0.93%。对不同 CT 灰度分布情况下玉米胚乳裂纹检测结果表明, 该模型对较小灰度、较大灰度、混合灰度 3 种玉米胚乳裂纹图像的  $P$  分别为 100%、100%、93.3%,  $R$  分别为 100%、82.4% 和 79.8%, AP 分别为 99.5%、91.2% 和 86.8%。结果表明, 所设计模型能有效实现玉米胚乳裂纹的检测, 同时模型鲁棒性高, 内存占用量小, 可为玉米浸种过程胚乳裂纹的自动监测提供借鉴。

**关键词:** 玉米胚乳裂纹; YOLO v5; CT 扫描; 旋转目标检测; 机器视觉

中图分类号: TP391.4 文献标识码: A 文章编号: 1000-1298(2023)03-0394-08

OSID: 

## Endosperm Crack Detection Method for Seed Dipping Maize Based on YOLO v5 – OBB and CT Technology

SONG Huabo<sup>1,2</sup> JIAO Yitao<sup>1,2</sup> HUA Zhixin<sup>1,2</sup> LI Rong<sup>1,2</sup> XU Xingshi<sup>1,2</sup>

(1. College of Mechanical and Electronic Engineering, Northwest A&amp;F University, Yangling, Shaanxi 712100, China

2. Key Laboratory of Agricultural Internet of Things, Ministry of Agriculture and Rural Affairs, Yangling, Shaanxi 712100, China)

**Abstract:** Seed immersion is an important pre-sowing seed enhancement technology in maize production, and efficient detection of cracks during seed immersion is the basis for analyzing the change pattern of endosperm cracks during seed immersion, which is one of the keys to the selection and breeding of good varieties of traits, and there are still difficulties such as internal endosperm cracks are not visible and the degree of automation is not high. Based on CT scanning technology, a rotating target detection network named YOLO v5 – OBB was designed based on YOLO v5n detection network, where OBB used rotating rectangular box instead of normal rectangular box and added CA model in the Backbone part. The network used a rotating rectangular box instead of a normal rectangular box, and added CA model in the Backbone part, and also used Skew – NMS for non-maximal suppression to obtain the final prediction box, so as to achieve the detection of corn endosperm cracks with relatively large length and width and different directions. After 300 iterations of training, the model had a precision of 94.2%, a recall of 81.7%, and an average precision of 88.2% on the test set, with model size of 4.21 MB and average

收稿日期: 2022-06-18 修回日期: 2022-07-25

基金项目: 国家重点研发计划项目(2019YFD1002401)

作者简介: 宋怀波(1980—), 男, 教授, 博士生导师, 主要从事图像处理和模式识别理论研究, E-mail: songyangfeifei@163.com

detection time of 0.01 s for a single image, which improved the AP value by 15.0, 16.9, and 7.0 percentage points compared with the SASM, S<sup>2</sup>A-Net, and ReDet models, respectively, and the average detection time of single image was reduced by 0.19 s, 0.22 s, and 0.46 s, respectively, while the YOLO v5-OBB model size was 1.50%, 1.43%, and 1.73% of the SASM, S<sup>2</sup>A-Net, and ReDet models, respectively, with an increase in AP value of 0.6 percentage points, a decrease in model size of 0.19 MB and an unchanged average detection time of 0.01 s for a single image compared with that of the YOLO v5 network with horizontal rectangular box labeling. Comparing the crack length information obtained from the YOLO v5-OBB network after obtaining the crack target frame coordinate information with the real length of the crack obtained in DragonflyEZ software, the absolute error of both was 0.04 mm and the relative error was 0.93%. The results on the detection of corn endosperm cracks with different CT gray value distributions showed that the model had *P* values of 100%, 100%, and 93.3%, *R* values of 100%, 82.4%, and 79.8%, and AP values of 99.5%, 91.2%, and 86.8% for the three types of corn endosperm crack images with smaller gray values, larger gray values, and mixed gray values, respectively. The results showed that the designed model can effectively achieve the detection of corn endosperm cracks, and at the same time, the model was highly robust and took up little storage, which can provide necessary technical support for the automatic monitoring of corn endosperm cracks during seed dipping.

**Key words:** corn endosperm cracking; YOLO v5; CT scanning; rotating target detection; machine vision

## 0 引言

浸种是农业生产中重要的播前增种技术,对田间作物具有显著影响,可促进快速出苗并提高出苗率<sup>[1]</sup>。谷物在浸种过程中受晶粒中水分梯度引起的拉应力和压应力的影响,最终会导致裂纹的形成<sup>[2]</sup>,裂纹有利于吸水,可作为水分扩散的输送通道<sup>[3]</sup>。玉米浸种时产生的内部微裂纹难以直接肉眼观察,因此,寻求一种胚乳裂纹自动识别方法,对实现玉米浸种时胚乳裂纹的自动检测具有重要意义。关于玉米裂纹检测的已有研究<sup>[4-7]</sup>都旨在检测种子表面或延伸到表面的可见裂纹,对于种子胚乳内部的不可见微裂纹研究相对较少。

由机械应力引起的果皮裂纹较易检出,但由热、湿气或机械应力引起的内部裂纹难以识别,因此需要更准确、更自动的评估系统,如 CT 和图像分析等<sup>[8]</sup>。近几年,X射线计算机断层扫描技术已被应用于量化植物结构分析<sup>[9]</sup>,它是一种放射成像技术,通过感兴趣的样本生成非破坏性的连续切片图像并对扫描对象进行三维重建<sup>[10-11]</sup>。X射线计算机断层扫描技术具有非破坏性、非侵入性、高分辨率的特点<sup>[12-14]</sup>,允许在不同条件下对同一试样进行多次扫描<sup>[15]</sup>。目前 X 射线技术已用于玉米籽粒的尺寸和形状、应力裂缝和密度等的表征<sup>[16]</sup>。已有研究<sup>[17-19]</sup>都旨在利用 X 射线计算机断层成像技术可视化籽粒内部结构,对于自动检测胚乳内部裂纹信息的研究较少。

以往玉米种子内部裂纹的检测仅依靠传统的图像检测方法,随着卷积神经网络模型的逐步发

展<sup>[20]</sup>,改进和优化的模型越来越适用于裂纹的快速检测。随着研究人员不断优化 YOLO 系列算法<sup>[21-22]</sup>,其检测精度和速度正在稳步提高。诸多学者将深度学习算法应用于农业种子分析领域,文献[23]提出了一种深度学习算法与边缘检测阈值处理相结合的检测方法用于检测玉米胚乳内侧裂纹,该检测方法对开裂种子的识别准确率为 95.08%,未开裂种子的识别准确率为 95.75%。近年来,深度学习算法被广泛应用于遥感图像检测<sup>[24-25]</sup>。众多研究者对遥感图像中旋转目标的检测进行了深入研究,旋转目标检测算法可以对图像中任何方向和角度的目标进行检测,主要针对于长宽比高的目标,可为玉米胚乳裂纹的自动检测提供有效借鉴。基于以往研究,对于种子裂纹的检测主要集中于种皮以及延伸到种皮的可见内部裂纹,对于玉米浸种时产生的内部胚乳微裂纹自动检测目前相对较少。

本文探索一种自动检测玉米浸种时产生的内部胚乳微裂纹的方法,利用 CT 扫描技术获取玉米胚乳图像,并利用基于 YOLO v5 改进的旋转目标检测算法对其进行自动检测,获取胚乳图像中裂纹长度信息,以期为玉米籽粒浸种时内部裂纹变化监测提供参考。

## 1 材料与方法

### 1.1 试验设备与材料

仪器设备:nanoVoxel-1280 型桌面式微观结构三维扫描成像系统(最高空间分辨率 24 μm,最大样品扫描高度 130 mm,样品台最大承载质量 10 kg,工

作电压 20~80 kV, 工作电流 0~0.7 mA, 射线源最大功率 56 W, 有效成像视野 128 mm×128 mm, 转台 X 轴行程 200 mm, 探测器 X 轴行程 200 mm, 探测器 Y 轴行程 50 mm, 样品台旋转角度 360°, 天津三英精密仪器股份有限公司); 电子天平(量程 100 g); JOANLAB 型热板搅拌器(最高设置温度 380°C); 圆形玻璃培养皿(直径 12 cm)、水温计、吸水纸、镊子若干。

**试验对象:**选取典型常见的 3 个品种玉米籽粒作为研究对象, 分别为京彩糯 816、黑糯 4 号以及爆花玉米。

## 1.2 数据集制备

### 1.2.1 样品制备及处理

取每个玉米品种各 3 粒作为一组, 将其置于玻璃培养皿中进行浸种处理; 将玻璃培养皿放置于 JOANLAB 型热板搅拌器上用于控制浸种温度。控制浸种温度为常温( $(26 \pm 1)^{\circ}\text{C}$ ), 每隔 1.5 h 取出试验样品进行扫描, 浸种总时长 12 h。对试验样品进行浸种处理, 每隔 5 min 依次将样品放入培养皿中, 以便后续扫描工作。在达到设定的浸种时间时, 用镊子取出试验样品, 吸水纸吸干种子表面水分, 之后将其置于 CT 样品台上进行扫描。

### 1.2.2 粒籽 CT 扫描

利用 nanoVoxel-1280 型桌面式微观结构三维扫描成像系统对玉米籽粒进行 CT 扫描, 扫描场景如图 1 所示。将玉米籽粒平置于样品台上进行扫描, 扫描参数为: 电压 60 kV, 电流 0.6 mA, 射线源与样品之间的距离为 127.88 mm, 射线源与探测器之间的距离为 530.86 mm, 此时空间分辨率最高, 为 24  $\mu\text{m}$ , 扫描模式为连续 CT 扫描, 设置系统以 0.5° 为间隔对样品进行 360° 连续扫描, 扫描时长 3.5 min。



图 1 扫描场景

Fig. 1 Scanning scenes

### 1.2.3 粒籽数据处理

利用 VoxelStudio Recon 软件将 CT 扫描获得的籽粒二维图像信息重建为三维数据, 在重建前进行伪影校正操作去除连续 CT 扫描产生的环状伪影, 根据籽粒的空间位置, 设置数据重建大小为 1 280 体素  $\times$  1 280 体素  $\times$  500 体素, 重建后获得后缀为. raw 格式的三维体数据, 将数据导入三维可

视化软件 DragonflyEZ 中, 得到玉米籽粒内部 X-Y 方向的一系列切片, 对扫描数据进行中值滤波后根据玉米籽粒尺寸将切片图像裁剪为 600 像素  $\times$  600 像素并导出, 3 种类型玉米的 CT 横截面图像如图 2 所示, 从图中可以清晰地看到玉米的胚、胚乳、种脐、空腔、裂纹等结构。

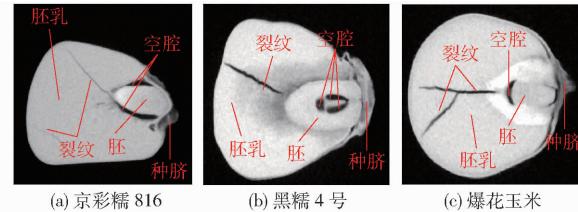


图 2 3 种类型玉米的 CT 横截面图像

Fig. 2 CT cross-sectional images of three types of corn

最终采集 3 种类型玉米的 1 847 幅胚乳裂纹图像, 其中京彩糯 816 玉米图像 535 幅、黑糯 4 号玉米图像 780 幅、爆花玉米图像 532 幅, 图像中 CT 灰度反映玉米胚乳各组织对 X 射线的吸收程度<sup>[19]</sup>, 灰度越高表明该组织密度越高, 因此裂纹灰度低于胚乳组织, 裂纹灰度越低表明该裂纹处胚乳组织受到的应力越大, 裂纹越明显。根据胚乳裂纹的典型特征, 按照图像中裂纹 CT 灰度的分布将图像分为较大灰度(35 361~65 535)、较小灰度(5 188~35 361)、混合灰度(5 188~65 535) 3 类, 其中较大灰度裂纹图像 422 幅, 较小灰度裂纹图像 493 幅, 混合灰度裂纹图像 932 幅, 3 种典型灰度的玉米胚乳裂纹图像如图 3 所示。

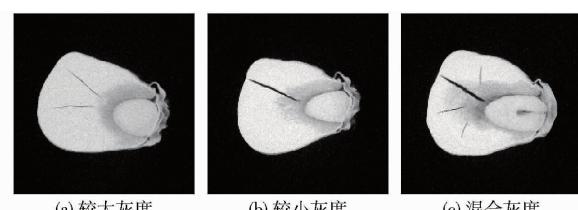


图 3 3 种典型灰度的玉米胚乳裂纹图像

Fig. 3 Three typical gray of corn endosperm crack images

### 1.2.4 数据集处理

由于部分裂纹与胚乳间灰度差异较小, 边缘特征不明显, 因此对得到的 1 847 幅图像进行锐化以得到更清晰的裂纹特征, 便于数据集的精确标注以及网络特征学习的精准。将数据集按照 8:1:1 的比例划分为训练集、验证集和测试集, 最终训练集 1 492 幅图像, 验证集 177 幅图像, 测试集 178 幅图像。训练集与验证集用于模型训练与单次训练结果的评估, 测试集用于最终模型的检测效果评估。利用 roLabelImg 工具对数据集进行人工标注, 获得与裂纹数据集对应的标签文件, 标签文件中包含与数据集图像对应的裂纹特征类别与坐标信息。

### 1.3 基于YOLO v5-OBB的玉米胚乳裂纹检测方法

#### 1.3.1 总体技术路线

本文的总体技术路线如图4(图中CBS为Conv2d+BN+SiLU, Conv2d为卷积操作,BN为归一化操作,SiLU为非线性激活函数,Upsample为上采

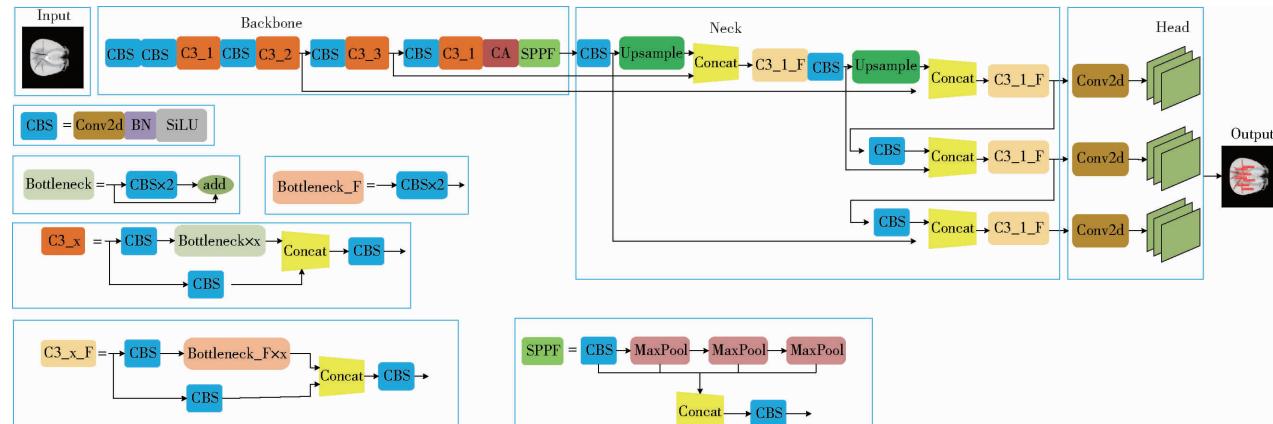


图4 总体技术路线

Fig. 4 Overall technical route

#### 1.3.2 YOLO v5n 网络模型

YOLO v5n<sup>[26]</sup>是YOLO v5系列中深度最小、特征图宽度最小的网络,其模型小、速度快,适用于较简单特征的目标检测任务。YOLO v5n包含Input、Backbone、Neck和Head共4部分,其中Input采用Mosaic与随机仿射变换两种方式对输入图像进行数据增强;Backbone对输入图像进行初步特征提取,最终获得3个有效特征层;Neck采用特征金字塔(Feature pyramid networks, FPN)+路径聚合网络(Path aggregation network, PAN)结构<sup>[27]</sup>,将Backbone提取到的3个有效特征层进行特征融合,结合不同尺度的特征信息,得到3个加强特征层,并将其传入Head;Head输出预测结果,通过非极大值抑制算法<sup>[28]</sup>(Non-maximum suppression, NMS)进行非极大值抑制并获得最终的预测框,从而得到目标的类别和位置信息。选取YOLO v5n网络模型,在此基础上进行改进,使之适用于玉米胚乳裂纹的旋转目标检测。

#### 1.3.3 模型改进

##### (1) Input

标注方式越精准,提供给网络训练时的冗余信息就越少,越有利于约束网络的训练方向和减少网络的收敛时间。原始YOLO v5n网络采用水平矩形框来确定目标的位置和类别,而玉米胚乳图像中裂纹呈细长特征,甚至贯穿整个胚乳面,并且相互交叉、方向不一,因此将旋转矩形框用于胚乳裂纹,更有利于裂纹目标的检测和下一步分析,两种矩形框标注效果如图5所示,从图5可以看出,采用原始矩

样操作,Concat为通道堆叠操作,add为特征图相加操作,MaxPool为最大池化操作,CA为位置注意力模块)所示,将利用roLabelImg工具标注完成的玉米胚乳裂纹图像送入YOLO v5-OBB目标检测网络,获得裂纹目标框,实现玉米胚乳裂纹的准确检测。

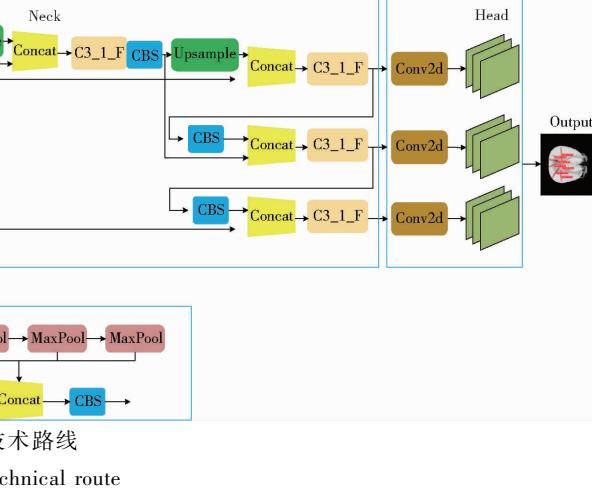


图4 总体技术路线

Fig. 4 Overall technical route

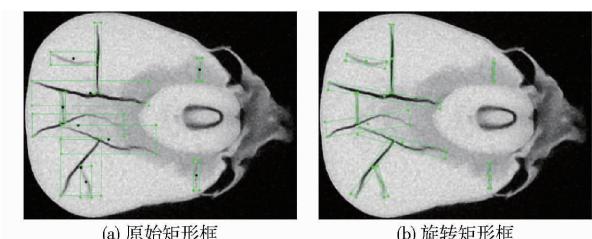


图5 两种矩形框标注效果对比

Fig. 5 Comparison of two types of rectangular box labeling effect

形框会造成目标真实框的重叠,甚至大真实框完全包围小真实框,目标框中的冗余信息较多,而采用旋转矩形框则避免了该问题。

常见的旋转框定义方法都存在角度边界问题,以长边定义法(角度定义为X正轴与矩形框长边的夹角,角度范围[-90°, 90°])为例,如图6所示,实线框为真实框,虚线框为网络预测框,在边界情况下,目标真实角度θ为-90°,预测角度为α-θ,网络学习到的角度差值为α-2θ,而真实差值为α,导致在周期变化的边界处损失值突增,网络学习难度增大。

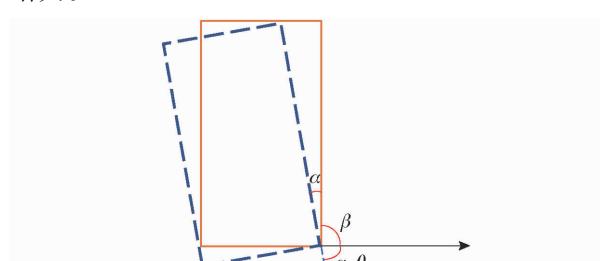


图6 旋转框的边界问题

Fig. 6 Boundary problem of rotating frame

环形平滑标签 (Circular smooth label, CSL)<sup>[29]</sup> 是用来解决边界问题的一种角度预测方法, 其公式为

$$CSL(x) = \begin{cases} g(x) & (\theta - r < x < \theta + r) \\ 0 & (x \geq \theta + r \text{ 或 } x \leq \theta - r) \end{cases}$$

式中  $g(x)$  —— 窗口函数  $r$  —— 窗口半径

它将角度的回归问题转化为对每一度角度的分类问题, 并且可以衡量预测框和真实框之间的角度距离。将长边定义法与 CSL 相结合以解决网络训练过程中旋转矩形框可能产生的边界问题, 长边定义法中旋转框的标签文件格式为 [class x\_c, y\_c, l, s, θ], 其中 class 为目标类别, x\_c, y\_c 分别为旋转框的中心点 x, y 坐标值, l 与 s 分别为旋转框的长边与短边。

YOLO v5n 网络中随机仿射变换数据增强方式中的旋转与错切变换会引起目标角度上的改变, 故在输入网络前将其关闭。

### (2) Backbone

由于旋转框相对于水平框增加了角度信息, 角度偏差也会影响检测精度, 因此在 C3\_1 与 SPPF 模块之间添加 CA<sup>[30]</sup> 位置注意力模块, 它将通道注意力分解为两个 1 维特征编码过程, 分别沿 2 个空间方向聚合特征, 以增强关注对象的表示。

### (3) Head

YOLO v5n 损失包含边框回归损失 (Complete intersection over union\_loss, CIoU\_loss)<sup>[31]</sup>、置信度损失和分类损失 (Binary cross entropy\_loss, BCE\_loss)<sup>[32]</sup>, 由于将 θ 视为分类任务来处理, 相当于将角度信息与边框参数信息解耦, 所以旋转框的损失计算部分也分为角度损失和水平边框损失两个部分, 边框回归损失仍采用 CIoU\_loss 函数, 角度分类损失先将 θ 标签经 CSL 处理后, 再用 BCE\_loss 计算损失。

传统的 NMS 算法只考虑了重叠度因子 (Intersection over union, IoU), 没有考虑角度问题, 因此采用 Skew-NMS<sup>[33]</sup> 进行非极大值抑制得到最终的预测框, 实现过程如下: 对输出的预测框按照得分进行降序排序; 遍历所有预测框, 将当前遍历的预测框与剩余的预测框进行交集运算得到相应的相交点集合, 并根据相交点集合组成的凸边形面积, 计算每两个预测框的 IoU; 滤除大于设定阈值的预测框, 保留小于设定阈值的预测框。

### 1.3.4 胚乳裂纹长度计算

在同等 CT 扫描参数下, 将尺寸为 10 mm × 9 mm × 30 mm 的标准量块置于样品台中进行扫描, 数据处理后将其 X-Y 方向切片导出, 导出尺寸

600 像素 × 600 像素, 得到裂纹长度比例尺, 即每个像素点代表的裂纹真实长度。模型最后输出裂纹预测框的置信度与坐标信息, 根据预测框坐标信息对裂纹进行截取, 之后获取裂纹特征轮廓得到裂纹像素点个数, 并与比例尺相乘得到裂纹实际长度。

### 1.3.5 试验环境

算法试验过程在 Ubuntu 18.04.5 LTS 操作系统下进行, 处理器型号为 Intel(R) Xeon(R) Gold 5217 CPU 3.00 GHz (\* 2), 显卡为 Nvidia Tesla V100-PCIE-32 GB (Nvidia)。深度学习框架采用 PyTorch 1.8, 编程平台为 PyCharm, 编程语言为 Python 3.8, 所有对比算法均在相同环境下运行。

### 1.3.6 评价指标

采用精确率 P、召回率 R、平均精度 (AP) 对玉米胚乳裂纹检测模型进行评价。当 IoU 在 0.5 以上时为真正例情况, 当 IoU 小于 0.5 时为假正例情况, 当 IoU 为 0 时为假反例情况。精确率 P 表示在所有预测为玉米胚乳裂纹中真正裂纹的比率, 即预测的准确性, 召回率 R 表示在所有玉米胚乳裂纹中被正确预测的比率, 即预测正确的覆盖率, 平均精度 (AP) 是召回率与精确度乘积的积分, 是综合评价指标, 3 个指标的值都在 0 ~ 1 之间, 其值越接近 1, 表明训练所得模型检测性能越好。

### 1.3.7 训练参数

为加快训练速度, 模型参数设置为网络在 COCO 数据集上预训练后的权重, 在此基础上进行微调训练, 模型超参数设置批样本数量为 8, 动量因子为 0.937, 权重初始学习率为 0.01, 权重衰减系数为 0.0005, 训练迭代次数为 300。

## 2 结果与分析

### 2.1 训练结果

本文网络共训练 300 轮次, 网络训练过程各个指标变化如图 7 所示, P、R、AP 在前 100 轮次迭代中有稍许震荡, 之后逐渐上升, 损失值收敛速度较快, 当迭代次数达到 220 左右时, 模型逐渐达到饱和, 损失值在 0.13 左右波动。最终模型 P 为 98.09%, R 为 82.14%, AP(IoU 为 0.5) 为 89.26%。

### 2.2 检测效果

将不同灰度范围的玉米胚乳裂纹测试图像送入 YOLO v5-OBB 旋转目标检测算法中, 得到模型的 P 为 94.2%, R 为 81.7%, AP 为 88.2%, 识别不同灰度范围玉米胚乳裂纹效果如图 8 所示, 检测框框选出裂纹并标注置信度与类别, 图中不同灰度范围的胚乳裂纹均可准确识别, 表明该算法可以有效地检测出胚乳裂纹。

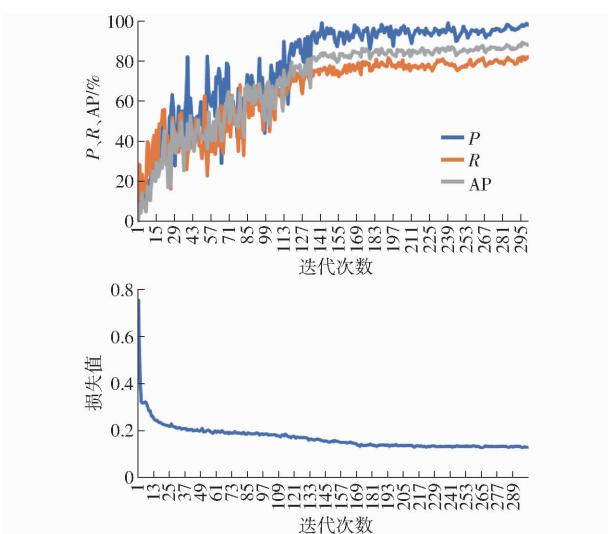


图 7 训练结果

Fig. 7 Training results

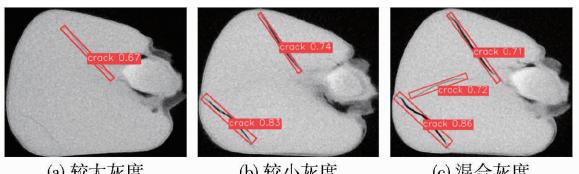


图 8 不同灰度裂纹检测效果

Fig. 8 Crack detection effect with different gray scales

### 2.3 裂纹长度获取

对标准量块扫描并处理后得到裂纹长度比例尺为 0.02 mm/像素, 以黑糯 4 号胚乳裂纹图像为例, 如图 9 所示, YOLO v5 - OBB 网络获取裂纹目标框坐标信息后, 对目标裂纹进行截取并获取裂纹特征轮廓, 得到裂纹像素点数并与比例尺相乘得到裂纹长度为 4.36 mm。

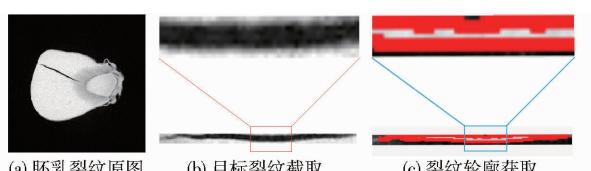


Fig. 9 Acquisition of crack length

裂纹实际长度如图 10 所示, 在 DragonflyEZ 软件中利用分析工具得到裂纹的实际长度为 4.32 mm, 两者绝对误差为 0.04 mm, 相对误差为 0.93%, 由此可知该方法可以较准确获取裂纹长度信息且误差较小。

### 2.4 不同旋转目标检测算法性能比较

为了评价 YOLO v5 - OBB 网络对玉米胚乳裂纹的检测效果, 在相同条件下, 分别基于 SASM<sup>[34]</sup>、S<sup>2</sup>A - Net<sup>[35]</sup> 和 ReDet<sup>[36]</sup> 旋转目标检测算法对玉米胚乳裂纹同一数据集进行训练, 之后利用测试集对训练完成后的模型进行评估。SASM、S<sup>2</sup>A - Net、



图 10 裂纹实际长度

Fig. 10 Actual length of cracks

ReDet 和 YOLO v5 - OBB 的性能如表 1 所示。

表 1 4 种旋转目标检测算法性能比较

Tab. 1 Performance of four rotating target detection algorithms

算法	AP/%	模型内存占用量/MB	检测时间/s
SASM	73.2	280	0.20
S <sup>2</sup> A - Net	71.3	295	0.23
ReDet	81.2	244	0.47
YOLO v5 - OBB	88.2	4.21	0.01

由表 1 可知, SASM、S<sup>2</sup>A - Net、ReDet 和 YOLO v5 - OBB 检测玉米胚乳裂纹的 AP 分别为 73.2%、71.3%、81.2% 和 88.2%, 模型内存占用量分别为 280、295、244、4.21 MB, 单幅图像平均检测时间为 0.20、0.23、0.47、0.01 s。对比测试结果可知: YOLO v5 - OBB 的 AP 分别比 SASM、S<sup>2</sup>A - Net、ReDet 高 15.0、16.9、7.0 个百分点; 模型内存占用量分别为 SASM、S<sup>2</sup>A - Net 和 ReDet 的 1.50%、1.43% 和 1.73%; 单幅图像平均检测时间分别比 SASM、S<sup>2</sup>A - Net、ReDet 快 0.19、0.22、0.46 s。

结果表明, 对于宽高比大的玉米胚乳裂纹检测, 经过对比分析各算法性能, YOLO v5 - OBB 网络综合性能较好, 能够满足检测的精度要求, 且算法模型较小, 能够实现玉米胚乳裂纹的快速检测, 利于模型迁移。

### 2.5 旋转矩形框与原始矩形框检测效果比较

为了分析 YOLO v5 - OBB 旋转目标检测算法与 YOLO v5 目标检测算法在胚乳裂纹检测的性能差异, 对 1847 幅玉米胚乳裂纹图像采用原始矩形框标注并送入 YOLO v5n 网络进行训练, 之后利用测试集对训练完成后的模型进行评估。

经测试, YOLO v5 目标检测算法检测玉米胚乳裂纹的 AP 为 87.6%, 模型内存占用量为 4.4 MB, 单幅图像平均检测时间为 0.01 s。对比测试结果可知: YOLO v5 - OBB 的 AP 比 YOLO v5 高 0.6 个百分点; 模型大小比 YOLO v5 小 0.19 MB; 单幅图像平均检测时间与 YOLO v5 相同, 均为 0.01 s。结果表明改进后的 YOLO v5 - OBB 网络性能较优, 能够适

用于玉米胚乳裂纹的检测。

采用两种矩形框标注的检测效果如图 11 所示,由图中可以看出,对于长宽比大并且相互交叉、方向不一的玉米胚乳裂纹,采用旋转矩形框进行检测能够精准地捕获裂纹位置且不会对其他裂纹造成干扰,有利于下一步裂纹长度的分析,而采用普通矩形框进行检测则会造成视觉干扰且存在明显的漏检,不利于下一步裂纹长度的分析。

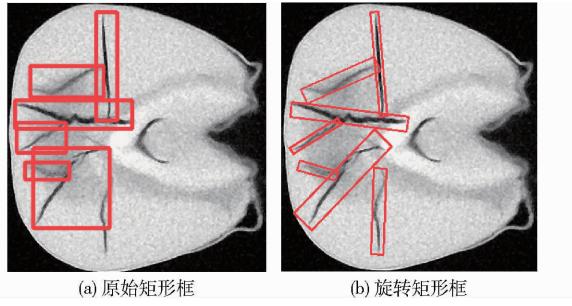


Fig. 11 Comparison of two kinds of rectangular box detection effect

### 3 讨论

#### 3.1 不同灰度情况下裂纹检测效果分析

为了验证 YOLO v5 - OBB 旋转目标检测算法对不同灰度玉米胚乳裂纹的识别效果,对测试集中 3 种不同灰度情况的胚乳裂纹图像分别进行测试并得到相应评价指标。

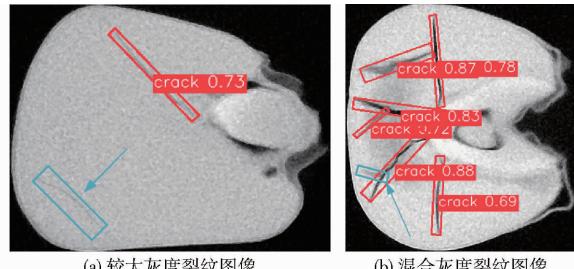
经测试,本方法检测较小灰度、较大灰度、混合灰度 3 种玉米胚乳裂纹图像的  $P$  分别为 100%、100%、93.3%, $R$  分别为 100%、82.4%、79.8%,AP 分别为 99.5%、91.2%、86.8%。对比 3 种不同灰度玉米胚乳裂纹图像的检测结果可知,YOLO v5 - OBB 模型对较小灰度裂纹图像的检测效果最好,其  $P$  为 100%, $R$  分别比较大灰度裂纹图像、混合灰度裂纹图像高 17.6、20.2 个百分点,AP 高 8.3、12.7 个百分点;对较大灰度裂纹图像的检测效果次之,其  $P$ 、 $R$ 、AP 分别比混合灰度裂纹图像高 6.7、2.6、4.4 个百分点。

分析可知,较小灰度裂纹图像中,裂纹与胚乳背景灰度差异较大,裂纹特征较明显,因此检测效果较好,AP 较高;而较大灰度裂纹图像中,裂纹与胚乳背景灰度差异较小,裂纹特征不明显,因此检测效果次之。3 种灰度分布裂纹图像的 AP 均在 85% 以上,结果表明 YOLO v5 - OBB 旋转目标检测算法可以准确识别出不同灰度分布的玉米胚乳裂纹图像且置信度较高。

#### 3.2 胚乳裂纹漏检分析

由 3.1 节可知,随着胚乳裂纹灰度增大,裂纹和

胚乳背景的灰度差异逐渐减小,裂纹特征不明显,导致检测效果下降,图 12 所示为测试集中裂纹被漏检的情况,图中蓝色箭头所指为被漏检的裂纹,由图中可知漏检裂纹存在于较大灰度裂纹图像与混合灰度裂纹图像中,且漏检裂纹均为较大灰度裂纹。



(a) 较大灰度裂纹图像  
(b) 混合灰度裂纹图像

图 12 胚乳裂纹漏检效果图

Fig. 12 Effect of endosperm crack leakage detection

分析出现玉米胚乳裂纹漏检的可能原因如下:

(1) 由检测结果可知,漏检裂纹均为较大灰度裂纹,该类裂纹与胚乳背景的灰度相差不大,裂纹特征不明显,导致网络在训练时提取特征存在困难,导致检测效果下降,部分较大灰度裂纹被漏检。

(2) 分析数据集可知,浸种后玉米由于湿应力产生的胚乳裂纹大部分为较小灰度裂纹,较大灰度裂纹比较少,并且裂纹形状、长短不一,因此在训练时较大灰度裂纹难以被网络学习到更丰富的特征,导致部分特征较少的较大灰度裂纹被漏检。

### 4 结论

(1) YOLO v5 - OBB 旋转目标检测算法检测玉米胚乳裂纹的  $P$  为 94.2%, $R$  为 81.7%,AP (IoU 为 0.5) 为 88.2%,模型大小为 4.21 MB,单幅图像平均检测时间为 0.01 s。与采用水平矩形框标注的 YOLO v5 网络相比,YOLO v5 - OBB 算法的 AP 提高 0.6 个百分点,模型大小减小 0.19 MB,单幅图像平均检测时间不变,两者均为 0.01 s;与 SASM、S<sup>2</sup>A - Net、ReDet 旋转目标检测算法对比,YOLO v5 - OBB 算法的 AP 分别高 15.0、16.9、7.0 个百分点,且在模型大小和检测速度方面优势明显,表明 YOLO v5 - OBB 算法可以实现玉米胚乳裂纹的高效检测。

(2) 针对不同灰度分布情况下的玉米胚乳裂纹,所提出的玉米胚乳裂纹检测方法都能较好地识别胚乳裂纹,说明基于 YOLO v5 - OBB 的玉米胚乳裂纹检测方法具有较好的鲁棒性。

(3) YOLO v5 - OBB 网络获取裂纹目标框坐标信息后,得到裂纹特征轮廓及长度信息,与在 DragonflyEZ 软件中得到的裂纹真实长度相比,两者绝对误差为 0.04 mm,相对误差为 0.93%,由此可知本方法可以较准确获取裂纹长度信息且误差较小。

## 参 考 文 献

- [1] CARRILLO-RECHE J, VALLEJO-MARIN M, QUILLIAM R S. Quantifying the potential of ‘on-farm’ seed priming to increase crop performance in developing countries. A meta-analysis[J]. *Agronomy for Sustainable Development*, 2018, 38(6) : 1 – 14.
- [2] PEREZ J H, TANAKA F, UCHINO T. Modeling of mass transfer and initiation of hygroscopically induced cracks in rice grains in a thermally controlled soaking condition; with dependency of diffusion coefficient to moisture content and temperature—a 3D finite element approach[J]. *Journal of Food Engineering*, 2012, 111(3) : 519 – 527.
- [3] DING Y, ZHANG G, NI C, et al. Understanding the mechanism of change in morphological structures, visualization features, and physicochemical characteristics of adlay seeds (*Coix lacryma-jobi* L.) : the role of heat soaking[J]. *Journal of Cereal Science*, 2020, 91(6) : 102892.
- [4] WANG L, HUANG Z, WANG R. Discrimination of cracked soybean seeds by near-infrared spectroscopy and random forest variable selection[J]. *Infrared Physics & Technology*, 2021, 115 : 103731.
- [5] ZHANG J, XUN Y, LI W. Identification and detection for surface cracks of corn kernel based on computer vision[C]//2007 ASAE Annual Meeting. American Society of Agricultural and Biological Engineers, 2007 : 073090.
- [6] 汪六三,黄子良,王儒敬. 基于近红外光谱和机器学习的大豆种皮裂纹识别研究[J]. *农业机械学报*, 2021, 52(6) : 361 – 368.  
WANG Liusan, HUANG Ziliang, WANG Rujing. Identification of soybean seed coat crack based on near infrared spectroscopy and machine learning[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52 (6) : 361 – 368. (in Chinese)
- [7] 张俊雄,荀一,李伟. 基于形态特征的玉米种子表面裂纹检测方法[J]. *光学精密工程*, 2007, 15(6) : 951 – 956.  
ZHANG Junxiong, XUN Yi, LI Wei. Detection of surface cracks of corn kernel based on morphology[J]. *Optics and Precision Engineering*, 2007, 15(6) : 951 – 956. (in Chinese)
- [8] DE CARVALHO M L M, VAN AELST A C, VAN ECK J W, et al. Pre-harvest stress cracks in maize (*Zea mays* L.) kernels as characterized by visual, X-ray and low temperature scanning electron microscopical analysis: effect on kernel quality[J]. *Seed Science Research*, 1999, 9(3) : 227 – 236.
- [9] HUGHES A, ASKEW K, SCOTSON C P, et al. Non-destructive, high-content analysis of wheat grain traits using X-ray micro computed tomography[J]. *Plant Methods*, 2017, 13(1) : 1 – 16.
- [10] DHONDT S, VANHAEREN H, VAN LOO D, et al. Plant structure visualization by high-resolution X-ray computed tomography[J]. *Trends in Plant Science*, 2010, 15(8) : 419 – 422.
- [11] GUSTIN J L, JACKSON S, WILLIAMS C, et al. Analysis of maize (*Zea mays*) kernel density and volume using microcomputed tomography and single-kernel near-infrared spectroscopy[J]. *Journal of Agricultural and Food Chemistry*, 2013, 61(46) : 10872 – 10880.
- [12] MATHERS A W, HEPWORTH C, BAILLIE A L, et al. Investigating the microstructure of plant leaves in 3D with lab-based X-ray computed tomography[J]. *Plant Methods*, 2018, 14(1) : 1 – 12.
- [13] LE T D Q, ALVARADO C, GIROUSSE C, et al. Use of X-ray micro computed tomography imaging to analyze the morphology of wheat grain through its development[J]. *Plant Methods*, 2019, 15(1) : 1 – 19.
- [14] RAMACHANDRAN R P, ERKINBAEV C, THAKUR S, et al. Three dimensional characterization of micronized soybean seeds using X-ray microtomography[J]. *Food and Bioproducts Processing*, 2021, 127(1) : 388 – 397.
- [15] LANDIS E N, KEANE D T. X-ray microtomography[J]. *Materials Characterization*, 2010, 61(12) : 1305 – 1316.
- [16] TAKHAR P S, MAIER D E, CAMPANELLA O H, et al. Hybrid mixture theory based moisture transport and stress development in corn kernels during drying: validation and simulation results[J]. *Journal of Food Engineering*, 2011, 106(4) : 275 – 282.
- [17] STRANGE H, ZWIGGELAAR R, STURROCK C, et al. Automatic estimation of wheat grain morphometry from computed tomography data[J]. *Functional Plant Biology*, 2014, 42(5) : 452 – 459.
- [18] BESANCON L, RONDET E, GRABULOS J, et al. Study of the microstructure of durum wheat endosperm using X-ray micro-computed tomography[J]. *Journal of Cereal Science*, 2020, 96 : 103115.
- [19] 陈树人,徐李,尹建军,等. 基于Micro-CT图像处理的稻谷内部损伤定量表征与三维重构[J]. *农业工程学报*, 2017, 33(17) : 144 – 151.  
CHEN Shuren, XU Li, YIN Jianjun, et al. Quantitative characterization of grain internal damage and 3D reconstruction based on Micro-CT image processing[J]. *Transactions of the CSAE*, 2017, 33(17) : 144 – 151. (in Chinese)
- [20] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[C]// European Conference on Computer Vision. Springer, Cham, 2016 : 21 – 37.
- [21] REDMON J, FARHADI A. YOLO v3: an incremental improvement[J/OL]. <https://doi.org/10.48550/arXiv.1804.02767>.
- [22] GE Z, LIU S, WANG F, et al. YOLO x: exceeding YOLO series in 2021[J/OL]. <https://doi.org/10.48550/arXiv.2107.08430>.

57–63.

KANG Jianming, LI Shujun, YANG Xuejun, et al. Virtual simulation and power test of disc type ditcher based on multi-body dynamics[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(1): 57–63. (in Chinese)

[22] 陈浩维. 浅谈永磁同步电机的技术优势及应用前景[J]. 内蒙古科技与经济, 2020(9): 81–82.

CHEN Haowei. Talking about the technical advantages and application prospects of permanent magnet synchronous motors[J]. Inner Mongolia Science and Technology and Economy, 2020(9): 81–82. (in Chinese)

[23] 张美迪. 电动汽车电池的现状及发展趋势[J]. 内燃机与配件, 2019(15): 230–231.

ZHANG Meidi. Status and development trend of electric vehicle batteries[J]. Internal Combustion Engines and Accessories, 2019(15): 230–231. (in Chinese)

[24] 李一, 王付胜, 杨淑英, 等. 基于浮动桥共中线开绕组拓扑的永磁同步电机矢量控制策略研究[J]. 中国电机工程学报, 2022, 42(13): 4942–4955.

LI Yi, WANG Fusheng, YANG Shuying, et al. Research on vector control strategy of permanent magnet synchronous motor based on floating bridge common centerline open winding topology[J]. Proceedings of the CSEE, 2022, 42(13): 4942–4955. (in Chinese)

[25] 王恩童, 刘宗锋, 卢纪丽, 等. 电动汽车锂电池自放电行为的温度特性[J]. 电源技术, 2019, 43(8): 1319–1321, 1347.

WANG Entong, LIU Zongfeng, LU Jili, et al. Temperature characteristics of self-discharge behavior of electric vehicle lithium batteries[J]. Power Technology, 2019, 43(8): 1319–1321, 1347. (in Chinese)

(上接第 401 页)

[23] ZHANG Y, LV C, WANG D, et al. A novel image detection method for internal cracks in corn seeds in an industrial inspection line[J]. Computers and Electronics in Agriculture, 2022, 197: 106930.

[24] KUSSL N, LAVRENIUK M, SKAKUN S, et al. Deep learning classification of land cover and crop types using remote sensing data[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(5): 778–782.

[25] ZHANG Z, GUO W, ZHU S, et al. Toward arbitrary-oriented ship detection with rotated region proposal and discrimination networks[J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(11): 1745–1749.

[26] ZHAI N. Detection using YOLO v5n and YOLO v5s with small balls[C]// International Conference on Computer Graphics, Artificial Intelligence, and Data Processing (ICCAID 2021). SPIE, 2022: 428–432.

[27] TRINH H C, LE D H, KWON Y K. PANET: a GPU-based tool for fast parallel analysis of robustness dynamics and feed-forward/feedback loop structures in large-scale biological networks[J]. PloS One, 2014, 9(7): 1–9.

[28] NEUBECK A, VAN GOOL L. Efficient non-maximum suppression[C]// 18th International Conference on Pattern Recognition (ICPR06). IEEE, 2006: 850–855.

[29] YANG X, YAN J. Arbitrary-oriented object detection with circular smooth label[C]// European Conference on Computer Vision. Springer, Cham, 2020: 677–694.

[30] 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: 13708–13717.

[31] 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: 12993–13000.

[32] ZHOU J, JIANG P, ZOU A, et al. Ship target detection algorithm based on improved YOLO v5[J]. Journal of Marine Science and Engineering, 2021, 9(8): 1–14.

[33] MA J, SHAO W, YE H, et al. Arbitrary-oriented scene text detection via rotation proposals[J]. IEEE Transactions on Multimedia, 2018, 20(11): 3111–3122.

[34] HOU L, LU K, XUE J, et al. Shape-adaptive selection and measurement for oriented object detection[C]// Proceedings of the AAAI Conference on Artificial Intelligence, 2022.

[35] HAN J, DING J, LI J, et al. Align deep features for oriented object detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 60: 5602511.

[36] HAN J, DING J, XUE N, et al. Redet: a rotation-equivariant detector for aerial object detection[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 2785–2794.