doi:10.6041/j.issn.1000-1298.2024.S2.029

基于纹理感知模块改进的杂交水稻制繁种杂株检测方法

杨惇泓　王永维　王　俊
（浙江大学生物系统工程与食品科学学院，杭州 310058）

摘要：除杂是杂交水稻制繁种过程中保证种子纯度的关键步骤。为了防止杂株产生异常花粉影响杂交优势，除杂作业需要反复人工操作，耗费大量的人工和时间。田间杂株的自动化地识别是实现机械化和自动化除杂的基础。为了实现杂交水稻制繁种杂株的自动化精确检测，首先使用无人机航拍采集含有杂株的杂交水稻制繁种田俯拍图像，通过中心裁剪获得无畸变的高质量图像，标注出图像中的杂株目标后经过几何变化和颜色变化进行数据增强，获得杂交水稻制繁种田间杂株数据集。针对图像数据集中杂株和正常植株之间的高相似度，提出了一种杂株目标检测网络模型T-CenterNet2，在CenterNet2网络的特征金字塔网络中添加纹理感知模块，这一模块通过重组通道信息获得特征图中的纹理特征，进而增强杂株目标和背景的特征差异；并重新设计了损失函数，添加测量纹理特征和标签真值之间差异的纹理损失，用于控制纹理感知模块；针对除杂的实际作业情况引入DIoU作为边界框损失，通过增加预测框和标签中心点的距离惩罚项以提高网络预测的目标中心点准确度。为了验证各项改进对模型的性能提升，首先使用mAP和召回率作为评价指标描述模型对杂株目标的检测效果，将改进后模型与原始模型CenterNet2以及4种典型模型(Faster R-CNN、FCOS、YOLOX、DeTR)进行对比，实验结果表明改进后T-CenterNet2模型mAP达到86.4%，较原始模型提高11.0个百分点，召回率达到82.5%，较原始模型提高11.6个百分点，而典型模型最高mAP和召回率仅为73.1%和66.2%，T-CenterNet2模型取得明显的优势。其次对比了不同损失函数组合对模型收敛速度和检测精度的影响，其中具有权重的纹理损失和DIoU组取得最佳结果，证明重新设计的损失函数有效适用于杂株检测任务。改进后模型具有较高的检测精度和鲁棒性，能够实现良好的杂株检测效果。

关键词：杂交水稻；异常检测；目标检测
中图分类号：TP391　　**文献标识码：**A　　**文章编号：**1000-1298(2024)S2-0286-08

Hybrid Rice Breeding Abnormal Plant Detection Method Improved on Texture Cognition Module

YANG Dunhong　WANG Yongwei　WANG Jun
(*Department of Biosystems Engineering and Food Science*, *Zhejiang University*, *Hangzhou* 310058, *China*)

Abstract: Abnormal plant removal is a critical step in ensuring seed purity during hybrid rice seed production. To prevent abnormal plants from producing abnormal pollen that could compromise hybrid vigor, current abnormal plant removal operations require repeated manual efforts, consuming significant time and labor. The automation of abnormal plant identification in the field is fundamental to achieve mechanized and automated removal. Aiming to achieve automated and precise detection of abnormal plant in hybrid rice seed production, UAV aerial images of hybrid rice seed production fields containing abnormal plants were collected, and high-quality and distortion-free images were obtained through center cropping. The abnormal plants in the images were annotated, and data augmentation was performed through geometric and color transformations to create a dataset of abnormal plants in hybrid rice seed production fields. To address the high similarity between abnormal and normal plants in the image dataset, a novel abnormal plant detection network model, T-CenterNet2, was proposed. This model enhanced the CenterNet2 network by incorporating a texture-aware module within the feature pyramid network, which reorganized channel information to extract texture features from the feature maps, thereby increasing the feature distinction between abnormal plants and the background. Additionally, a combination of loss functions was designed,

收稿日期：2024-08-10　修回日期：2024-09-20
基金项目：国家重点研发计划项目(2023YFD2000402)、国家现代农业产业技术体系项目(CARS-01)、浙江省“三农九方”农业科技协作计划项目(2023SNJF048)和浙江大学科研项目(XY2023042)
作者简介：杨惇泓(1999—)，男，硕士生，主要从事智能农业装备研究，E-mail: 22113003@zju.edu.cn
通信作者：王永维(1975—)，男，教授，博士生导师，主要从事智能农业装备研究，E-mail: wywzju@zju.edu.cn

including a texture loss that measured the difference between texture features and label ground truth to control the texture-aware module. DIoU was introduced as the bounding box loss to improve the accuracy of target center point predictions, in line with the practical requirements of abnormal plant removal operations. The effects of different loss function combinations on model convergence speed and detection accuracy were compared, with the combination of weighted texture loss and DIoU yielding the best results, demonstrating the effectiveness of the redesigned loss function for abnormal plant detection tasks. Using mAP and recall rate as evaluation metrics, the improved model was compared with the original CenterNet2 model and four typical models—Faster R-CNN, FCOS, YOLOX, and DeTR. Experimental results showed that the improved T-CenterNet2 model achieved an mAP of 86.4%, an increase of 11 percentage points over the original model, and a recall rate of 82.5%, an increase of 11.6 percentage points over the original model. The highest mAP and recall rate among the typical models were only 73.1% and 66.2%, respectively. The enhanced model exhibited high detection accuracy and robustness, effectively achieving reliable abnormal plant detection.

Key words: hybrid rice; anomaly detection; object detection

0　引言

杂交水稻因其高产、抗病、适应性强等优势被广泛推广和应用，但自交后代会出现性状分离导致杂交水稻不能留种，因而需要每年制种。在制繁种过程中，往往存在一定量的由落田谷或变异导致的杂株，这些杂株在授粉期带来其他品种的花粉，直接影响杂交水稻种子的纯度，最终导致大田生产产量下降、抗病能力减弱，造成严重的经济损失[1-2]。在杂交水稻制繁种过程中，除杂是确保杂交水稻种子纯度至关重要的环节。目前的除杂方法完全依靠手工作业完成，在田间反复进行人工识别和清除需要大量的人工投入。为了实现除杂过程的机械化和自动化，首先需要在田间检测杂株以实现杂株定位。在杂交水稻制繁种过程中可能出现多种不同的杂株，其中最主要的杂株类型为株高异常杂株，这类杂株相比正常杂交水稻植株生长速度快，在拔节期间表现为较正常植株高，颜色淡的突出个体[3]。无人机航拍可以自动地获取田块的俯拍图像，适合用于植物个体高效检测和定位。

目前许多针对田间异常情况的研究使用深度学习方法，对多种农业对象的图像进行目标或区域识别，其中的典型应用包括识别小麦或水稻田中的倒伏情况[4-9]，使用语义分割的方法识别作物倒伏区域；识别作物叶片病虫害，其中有识别图像中主要病虫害类型的分类方法[10-14]和检测图像中病虫害区域的目标检测或语义分割方法[15-18]；或是检测田间的杂草，这些研究基于具体环境和杂草特征设计算法[19-25]，在作物生长的不同时期识别各种杂草。

但目前的相关研究或依靠在实验室条件中观察得到的细致特征细节，或是针对具有明显外观差异的不同类植物进行种间区分，同时许多研究的重点在于轻量化模型以适应实际作业环境而非更精确的识别。杂株检测与已有的田间异常检测研究的区别在于：杂株和背景中的正常植株均为水稻植株，其形态相似且颜色相近，比种间区分更为困难。目前还没有能够适用于这种植株相似度很高的种内区分场景下的应用。

目前大多数深度学习模型的特征提取能力不足，难以精确识别异常植株，需要开发一种针对杂株目标的深度学习模型，以实现对杂株的精确检测。针对目标特征不突出的问题，本文提出一种基于CenterNet2改进的深度学习目标检测网络架构，称为T-CenterNet2(Texture-CenterNet2)。通过引入纹理感知模块和纹理损失，提升网络对图像中杂株特征的敏感度，提高对杂交水稻制繁种过程田间株高异常杂株的识别准确性，以期为后续的杂株定位和清除工作提供支持。

1　材料和方法

1.1　数据来源

杂交水稻制繁种杂株图像采集于浙江省湖州市和海宁市的制繁种基地，种植的水稻母本品种分别为浙粳6a、浙粳7a，图像采集时间为2023年8月7日、8月8日、8月17—19日，此时制种田中的正常杂交水稻不育系母本处于拔节期，高度和颜色均一致。采集时风力情况均为无风或微风，水稻植株的形态不受风力影响。使用搭载禅思P1 35 mm镜头的大疆经纬RTK M300型无人机进行图像采集，该无人机具有航路飞行功能，能够自动地按照设定的路线飞行并以一定间隔拍摄图像，图像采集时的航线参数设置为飞行高度40 m，飞行速度1.6 m/s，航向重叠率为80%，旁向重叠率为90%。

1.2　数据集建立

无人机采集的原始图像尺寸为8 192像素×5 460像素，分辨率过高不利于深度学习模型进行学习，需要对原始图像进行切分。考虑到图像之间存在一定重叠率，并且图像边缘存在畸变，故首先对图像进行裁剪预处理，将图像四周的部分舍去，仅保留中央的2 700像素×

1 800像素的图像，经过筛选，得到380幅存在杂株或杂草目标的图像。在裁剪后得到的图像上进行标注，使用LabelImg软件标注出图像上杂株和杂草目标的矩形区域，形成json格式的标注文件记录矩形四角位置。将380幅图像按7∶2∶1的比例分为训练集、验证集和测试集，对其中的训练集和验证集进行数据增强。

为了提高数据集的质量，增强模型的泛化能力，采用水平或竖直翻转、改变色度或亮度的方式进行数据增强。对于训练集和验证集中共342幅图像，首先对每幅图像随机地进行水平或竖直翻转，得到共计684幅图像，再同样地对经过翻转扩增的数据集应用改变色度或改变亮度操作，最终得到的训练集共1 064幅，验证集304幅；测试集未经过扩增，共38幅。

1.3 网络模型

1.3.1 纹理感知模块

在杂交水稻制种过程杂株检测任务中，杂株目标和背景的相似性使得网络难以捕获关键特征，使用纹理感知模块[26]来增强目标和背景之间的纹理差异，帮助网络区分正负样本。

纹理感知模块接收不同分辨率的特征图作为输入f_{in}，首先使用1×1卷积降低特征图的通道数得到f'_{in}，然后进行纹理重组过程以生成纹理特征图。纹理重组过程的操作方式如下：对于特征图上的每个像素，将各通道特征组成的特征向量与其转置相乘，得到偏倚协方差矩阵，以表示不同通道之间特征的相关性。将每个像素的偏倚协方差矩阵的上三角重塑为特征向量并按空间位置重新连接，得到纹理特征图F，这一特征图能包含丰富的纹理特征信息。纹理重组过程如图1所示。

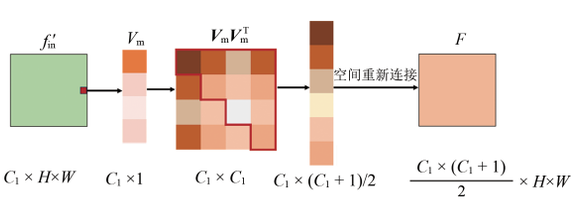

图1 纹理重组过程

Fig. 1 Texture reconstruction process

使用两个3×3卷积从F中学习得到两个参数图β和γ，用于与经过规范化的原始特征图进行计算，调整输入的特征以突出目标和背景之间的纹理差异，纹理感知模块最终的输出特征图f_{out}由调整后的特征图f_b和原始特征图经过一个3×3卷积得到，即

$$f_1 = \frac{f'_{in} - \sigma(f'_{in})}{\mu(f'_{in})} \tag{1}$$

$$f_b = \gamma f_1 + \beta \tag{2}$$

$$f_{out} = \mathrm{conv}(f_b) + f_{in} \tag{3}$$

其中f'_{in}由输入特征图经过3×3卷积得到，$\sigma(f'_{in})$和$\mu(f'_{in})$分别为f'_{in}的标准差和平均值。模块的整体结构如图2所示。

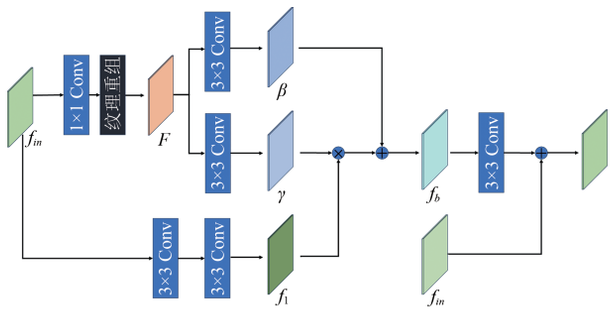

图2 纹理感知模块

Fig. 2 Texture cognition module

1.3.2 T-CenterNet2架构

CenterNet[27]作为无需锚框的目标检测算法，其核心原理在于用目标的中心位置代表目标，通过学习关键点热力图以预测目标位置，而目标尺寸等其他信息通过图像特征回归得到。实验中使用的基础网络是在CenterNet的基础上改进得到的CenterNet2[28]，相比于初始版本，CenterNet2使用特征金字塔网络处理多尺度信息，其网络总体架构由负责特征提取的骨干网络、处理多尺度信息的特征金字塔网络和负责产生预测的检测头组成，使用纹理感知模块改进得到的T-CenterNet2结构如图3所示。

其中骨干网络为ResNet101，特征金字塔网络接收骨干网络的C3~C5层输出，其特征图尺寸分别为128×128、64×64、32×32。这些特征图通过横向连接，上采样层和合并层得到5层不同分辨率的特征图。这一过程中，将原始的横向连接层即1×1卷积替换为纹理感知模块，然后依次将高层特征图进行上采样再与前一层特征图叠加，以此得到P3~P5特征图，同时对P5使用3×3卷积进行两次下采样，得到分辨率最低的两层特征图P6、P7，其尺寸为16×16和8×8。对以上P3~P7共5层特征图分别进行检测，使用的检测头由分类分支和回归分支组成，各采用5层3×3卷积得到分类热图和预测框位置。相比简单的1×1卷积横向连接，通过在特征金字塔网络的横向连接处加入纹理感知模块，可以在特征图中加入强大的纹理信息，对原本简单横向传播的特征图进行纹理特征增强。

1.4 损失函数

在深度学习网络训练过程中，损失函数用于评估预测值与真实值之间的差距，并实现反向传播以控制网络参数的优化，使得模型达到最好的预测效果，损失函数的选择会影响模型的收敛速度和最终的检测效果。目标检测领域常使用边界框损失函数和分类损失函数来分别描述两个任务分支的效果，针对改进后的网络架构和实际检测目标的特点对损失函数进行了重新设计。实验的最终损失函数由分类损失L_{cls}、边界框损失L_{DIoU}和纹理损失$L_{texture}$共3部分按损失权重w_1、w_2和w_3线性组成，其中分类损失相比原始模型未做改动，损失函数公式为

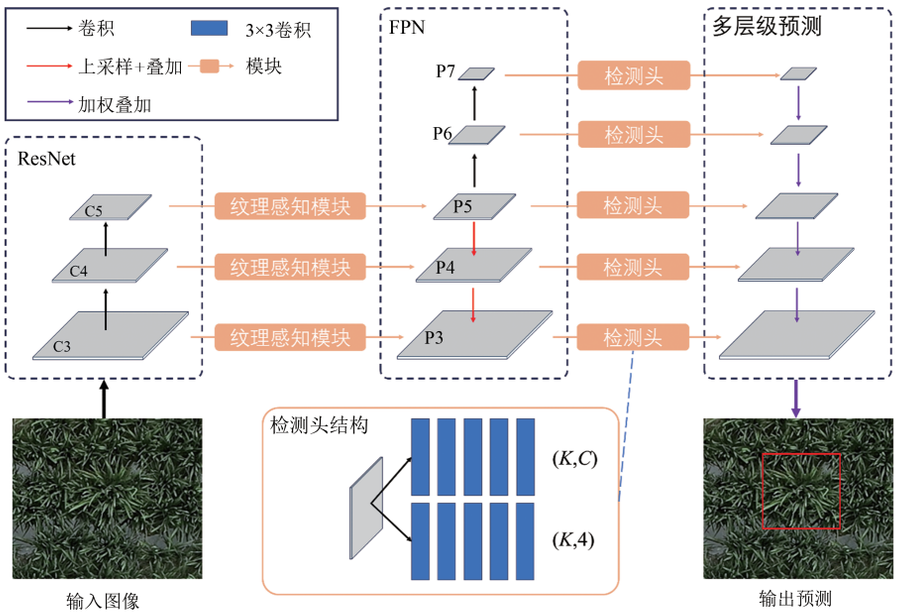

图 3　T-CenterNet2 模型结构

Fig. 3　Architecture of T-CenterNet2

$$L = w_1 L_{cls} + w_2 L_{DIoU} + w_3 L_{texture} \tag{4}$$

1.4.1　纹理损失

为了增强纹理损失模块从背景之中突出目标的能力，设计了纹理损失用于控制参数图β和γ，对于尺寸为$M\times N$的参数图和地面真值图进行以下操作以计算纹理损失：首先对参数图和地面真值通过最大池化进行下采样，然后将参数图重塑为参数向量，在参数向量的基础上计算纹理矩阵，公式为

$$\boldsymbol{A}^{F}_{m,n} = \frac{\boldsymbol{h}_m^{\mathrm{T}}\boldsymbol{h}_n}{\left\|\boldsymbol{h}_m^{\mathrm{T}}\right\|_2\left\|\boldsymbol{h}_n\right\|_2} \tag{5}$$

其中$\boldsymbol{h}_m$和$\boldsymbol{h}_n$分别为m和n位置上各通道参数组成的$1\times C$参数向量，逐位置计算后得到尺寸为$(M\times N)\times(M\times N)$的纹理矩阵$\boldsymbol{A}^{F}$。然后类似地计算地面真值的纹理矩阵，公式为

$$\boldsymbol{A}^{gt}_{m,n} = \frac{\boldsymbol{C}_m^{\mathrm{T}}\boldsymbol{C}_n}{\left\|\boldsymbol{C}_m^{\mathrm{T}}\right\|_2\left\|\boldsymbol{C}_n\right\|_2} \tag{6}$$

其中$\boldsymbol{C}_m$和$\boldsymbol{C}_n$为标签向量，使得m和n位置的类别标签相同时$\boldsymbol{A}^{gt}_{m,n}$为1，标签完全不相同时为0。

最终的纹理损失由参数图纹理矩阵和地面真值纹理矩阵计算得到，为了解决异常目标在图像中所占面积通常很小导致的类不平衡问题，为纹理损失添加一个类比例权重，公式为

$$L_{texture} = \sum_m\sum_n \omega_m\omega_n\left\|\boldsymbol{A}^{F}_{m,n}, \boldsymbol{A}^{gt}_{m,n}\right\| \tag{7}$$

其中　　$\omega_m = 1 - \dfrac{N_m}{HW}$　　$\omega_n = 1 - \dfrac{N_n}{HW}$

N_m和N_n表示m和n位置对应的类别在整个图像中占的像素个数。此类比例权重将放大占比很小的目标区域产生的损失而抑制占比较大的背景部分产生的损失。

1.4.2　边界框损失

对于异常植株检测任务，目标边界框中心点位置的精确程度非常重要，因为这将直接影响后续的定位和清除效果。DIoU[29]是一种额外考虑了预测框和标签框中心点之间的相对距离的损失函数，相比原始模型中采用的GIoU损失函数更适合作为实验中的边界框损失，以增强定位误差的影响程度。DIoU损失函数计算式为

$$L_{DIoU} = L_{IoU} + \frac{\rho^2\left(b,b^{gt}\right)}{c^2} \tag{8}$$

其中L_{IoU}为普通的IoU损失，b和b^{gt}表示预测框和目标框的中心点，$\rho(b,b^{gt})$表示这两者之间的距离，c表示两者的最小外接矩形的对角线长度，DIoU相比IoU损失额外添加了归一化的框距离作为惩罚，能够使网络更关注预测框的位置准确性。

1.5　训练参数和评价指标

实验在搭载Intel（R）Core（TM）i9-13900F和NVIDIA GeForce RTX 4090的工作站上进行，操作系统为Windows 10。算法均使用基于Python 3.9和Pytorch 2.0.0的通用开源目标检测工具箱mmdetection实现。训练过程中，优化器类型为Adam，权重衰退指数为0.000 9，初始化学习率为0.000 2，批大小为8，总训练批次为250。

为了评估模型检测目标的准确性，选择类平均精确度（Mean average precision，mAP）和召回率作为评价指标。使用类平均精度作为评价指标可以有效地解决正样本数量少导致的类不平衡问题，使得占比不同的各种类提供的精度比例是相同的。

2　实验结果和讨论

为了评估改进后的T-CenterNet2方法对杂交水稻

制繁种田间杂株目标的检测性能，将实验结果与4种典型模型进行对比分析，其中包括典型两阶段目标检测算法Faster RCNN[30]、单阶段无锚框目标检测算法FCOS[31]和YOLOX[32]以及基于Transformer的目标检测算法DeTR[33]；同时为了证明纹理感知模块以及数据增强对模型杂株检测性能的影响，进行了消融实验以对比原CenterNet2网络和改进后网络的性能，并在原始数据集和增强后数据集上分别进行了训练。还进行了在T-CenterNet2中采用不同损失函数的对比实验，以验证纹理损失中的类比例权重和DIoU损失函数的作用。在每次实验的训练过程中采用了相同的骨干网络及预训练权重，并且保持相同的训练参数。

图4显示了各种模型在测试集测试上的结果，其中的图像是在实际预测图上裁剪得到的主要部分。

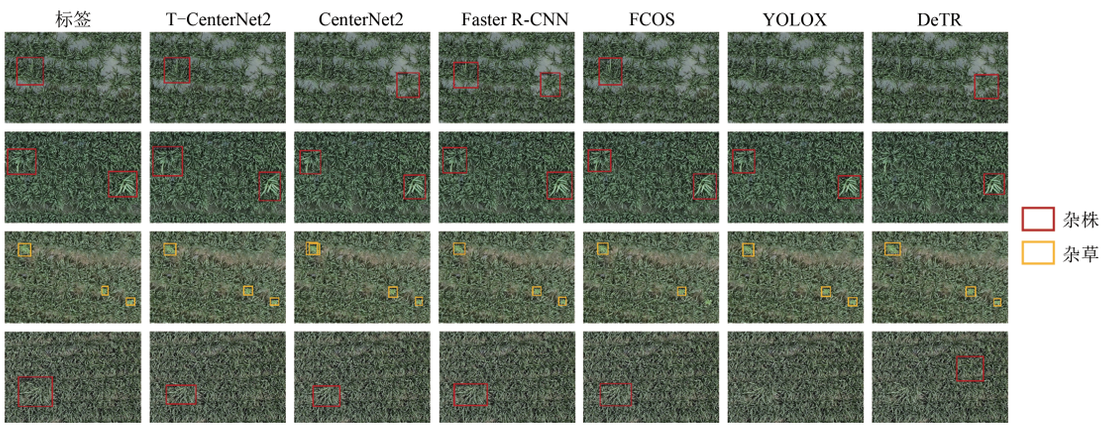

图4 目标检测结果可视化对比

Fig. 4 Visualization comparison of detection result

2.1 与典型模型检测结果的对比

不同模型的检测结果指标如表1所示。加入纹理感知模块的改进CenterNet模型mAP为86.4%，召回率为82.5%，能够有效地检测出田间杂株，其主要的误差来源于预测框的大小与真值的差异，而这在杂株检测任务中被认为是相对不重要的。4种典型模型Faster R-CNN、FCOS、YOLOX、DeTR的mAP分别为73.1%、71.9%、65.3%和66.9%，并且4种模型的召回率均低于67%，杂株识别效果较差；图4中结果表明，典型网络模型均存在一定程度的漏检和错检情况，其中漏检在杂株和正常植株颜色相近时4种模型都容易发生，相比之下对颜色差异明显的杂草目标错误较少，说明典型模型倾向于依靠简单的外观颜色进行预测；在错检情况中，YOLOX和DeTR主要将正常植株的边缘错误地认为是杂草，并且杂株检测的漏检非常严重，FCOS则倾向于将背景中的正常植株识别为杂株，导致假阳性样本过多。以上结果表明，典型模型不能准确提取和利用杂株特征，难以实现精准的杂株目标检测，并且受到相似特征的影响，容易混淆背景和目标。T-CenterNet2模型准确率和召回率明显优于4种典型模型，虽然参数量较大且推理速度较慢，但考虑实际应用中无人机航拍速度远低于模型推理速度，可以认为该模型能够满足田间实时作业需求。

2.2 纹理感知模块和数据增强对识别效果的影响

表2结果表明，通过在网络中加入纹理感知模块，mAP提高11.0个百分点，召回率提高11.6个百分点，明显提高了模型的精度。图4中结果表明，改进后杂株的错检和漏检问题明显改善，对杂草小目标的检出率也有提升。这说明纹理感知模块可以有效地利用通道间的纹理特征，并据此将特征图的杂株区域与背景的纹理差异放大，在不同特征图分辨率下分别使用纹理感知模块使得网络对不同层次特征的感知能力都有提升。从而实现了对与背景在外观性状和颜色十分相似的杂株目标更精确的识别效果。

表1 不同模型杂株目标检测结果

Tab. 1 Detection results of different models for abnormal plant targets

模型	mAP/%	召回率/%	参数量	推理速度/(f·s^{-1})
Faster R-CNN	73.1	66.2	9.92×10^7	19.8
FCOS	71.9	63.7	5.11×10^7	27.0
YOLOX	65.3	59.3	8.90×10^6	16.1
DeTR	66.9	53.8	6.05×10^7	34.0
T-CenterNet2	86.4	82.5	1.57×10^8	19.5

图5显示了原始数据集和扩增后数据集训练过程对比，数据增强使得训练后的模型mAP提高1.5个百分点，召回率提高1.0个百分点。数据增强提高了数据集的丰富程度，解决了因为杂株个体相对稀有导致数据量少的问题，使模型在不同环境因素下提取杂株特征、区分杂株与背景的能力更强，提高了模型的精度和泛化能力。

表2 消融实验和数据增强对比结果

Tab. 2 Ablation test and data augmentation results

模型	数据集图像数量	mAP/%	召回率/%	参数量	推理速度/(f·s^{-1})
T-CenterNet2	1 406	86.4	82.5	1.57×10^8	19.5
CenterNet2	1 406	75.4	70.9	5.13×10^7	33.3
T-CenterNet2	380	84.9	81.5	1.57×10^8	19.5

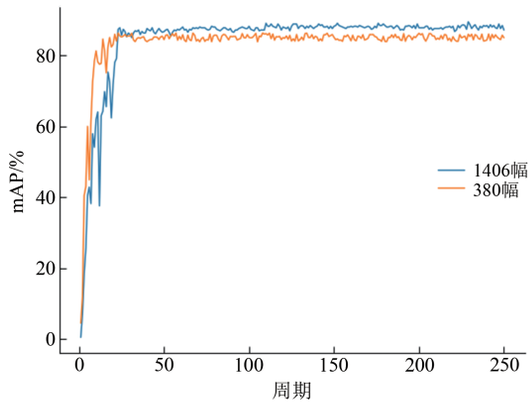

图5　数据增强前后mAP曲线

Fig. 5　The mAP curves before and after data augmentation

2.3　不同损失函数组合对模型训练的影响

损失函数是控制模型学习优化的关键环节，为了对比采用DIoU作为边界框损失函数和原模型中的GIoU损失函数时的性能差异，以及纹理损失中是否添加类比例权重对模型的影响，进行了G1~G4共4次损失函数组合不同的实验，结果如表3和图6所示。

表3　不同损失函数组合及其结果

Tab. 3　Different loss functions and their results

编号	添加损失权重	边界框损失	最佳轮次	mAP/%
G1	否	GIoU	229	84.3
G2	是	GIoU	213	85.0
G3	否	DIoU	155	85.3
G4	是	DIoU	70	86.4

注：GIoU为原始模型中采用的损失函数。

从表3和图6可知，为纹理损失加入类比例权重可以提高模型收敛速度，并能在两种损失函数组合中都实现更精准的检测，而DIoU相比GIoU能实现更高的精度。4组结果中，加入类比例权重且使用DIoU的组合取得最快

的收敛速度和最佳的检测精度，表现最优。这说明类比例权重有效地给目标杂株样本分配更大的权重，可以使模型在训练时更加专注于稀少的正样本，减少背景同时DIoU损失函数中直接约束了中心点距离，模型能更精确地调整预测框的位置，两者的组合使得最终的检测效果更好。

3　结论

（1）以CenterNet2为基础网络，针对杂交水稻制繁种田中杂株与正常植株相似度高难以提取特征的问题，设计了一种利用纹理特征强化背景和目标之间差异的杂株目标检测方法T-CenterNet2。该模型在杂交

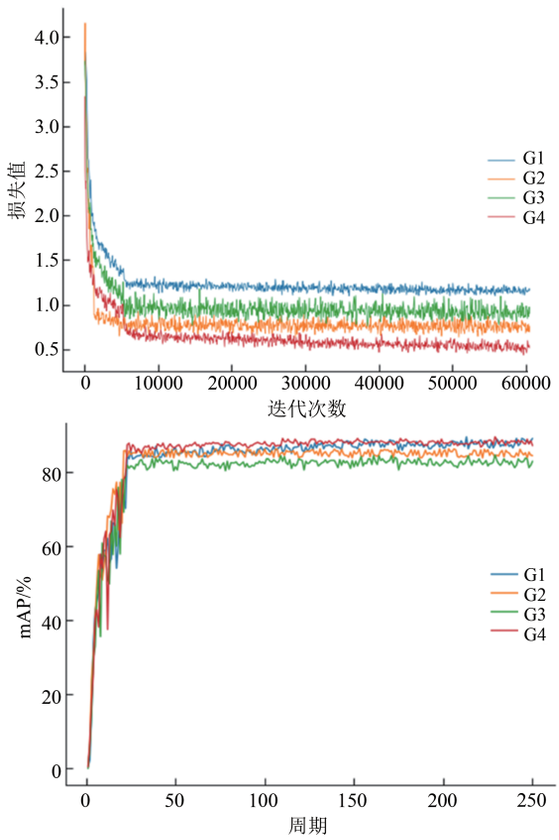

图6　不同损失函数组合的训练曲线

Fig. 6　Training curves for different combinations of loss functions

水稻制繁种田数据集上的mAP和召回率分别为86.4%和82.5%。

（2）将T-CenterNet2与4种典型模型Faster RCNN、FCOS、YOLOX、DeTR在测试集上进行对比，结果表明T-CenterNet2虽然参数量较大，mAP和召回率相比4种典型模型至少高13.3个百分点和16.3个百分点，对杂株的目标检测效果最佳，能够实现对杂株目标的自动化精确检测。

（3）不同损失函数设计的测试结果表明，为纹理损失添加类比例权重和采用DIoU作为边界框损失函数都能提高模型收敛速度和检测精度。

（4）对比在数据扩增前后的数据集上的训练结果，数据扩增使模型的mAP提高1.5个百分点，能够解决原始数据偏少的问题。

（5）改进后T-CenterNet2与原始网络CenterNet2消融实验结果表明，T-CenterNet相比原始模型mAP和召回率分别提高了11.0个百分点和11.6个百分点。纹理感知模块可以更好地利用不同通道中的纹理特征信息，提高模型对与背景相似的杂株目标的检测性能。

参　考　文　献

[1]　梅凯华，周强，王欢，等. 杂交水稻制种杂株形成的成因、识别技巧及质量控制[J]. 湖北农业科学，2009，48(5)：1060－1063.
MEI Kaihua，ZHOU Qiang，WANG Huan，et al.Causes，identification skills and total quality control countermeasures for abnormal plants in rice propagation and production[J]. Hubei Agricultural Sciences，2009，48(5)：1060－1063.(in Chinese)

[2] 邓鹏. 三系杂交水稻制种除杂技术[J]. 安徽农学通报(上半月刊), 2012, 18(17): 84-91.

[3] 陆传萍. 杂交水稻制种田间杂株识别技术[J]. 杂交水稻, 2004(1): 42-72.

[4] YANG M D, BOUBIN J G, TSAI H P, et al. Adaptive autonomous UAV scouting for rice lodging assessment using edge computing with deep learning EDANet[J]. Computers and Electronics in Agriculture, 2020, 179: 105817.

[5] 庞春晖, 陈鹏, 夏懿, 等. 用于小麦多生长阶段倒伏边界精准检测的分层交互特征金字塔网络(英文)[J]. 智慧农业(中英文), 2024, 6(2): 128-139.
PANG Chunhui, CHEN Peng, XIA Yi, et al. HI-FPN: a hierarchical interactive feature pyramid network for accurate wheat lodging localization across multiple growth periods[J]. Smart Agriculture, 2024, 6(2): 128-139. (in Chinese)

[6] 慕涛阳, 赵伟, 胡晓宇, 等. 基于改进的DeepLabV3+模型结合无人机遥感的水稻倒伏识别方法[J]. 中国农业大学学报, 2022, 27(2): 143-154.
MU Taoyang, ZHAO Wei, HU Xiaoyu, et al. Rice lodging recognition method based on UAV remote sensing combined with the improved DeepLabV3+ model[J]. Journal of China Agricultural University, 2022, 27(2): 143-154. (in Chinese)

[7] 杨蜀秦, 王鹏飞, 王帅, 等. 基于MHSA+DeepLab V3+的无人机遥感影像小麦倒伏检测[J]. 农业机械学报, 2022, 53(8): 213-219.
YANG Shuqin, WANG Pengfei, WANG Shuai, et al. Detection of wheat lodging in UAV remote sensing images based on multi-head self-attention Deeplab V3+[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(8): 213-219. (in Chinese)

[8] 龙佳宁, 张昭, 刘晓航, 等. 利用改进EfficientNetV2和无人机图像检测小麦倒伏类型[J]. 智慧农业(中英文), 2023, 5(3): 62-74.
LONG Jianing, ZHANG Zhao, LIU Xiaohang, et al. Wheat lodging types detection based on UAV image using improved EfficientNetV2 [J]. Smart Agriculture, 2023, 5(3): 62-74. (in Chinese)

[9] 申华磊, 苏歆琪, 赵巧丽, 等. 基于深度学习的无人机遥感小麦倒伏面积提取方法[J]. 农业机械学报, 2022, 53(9): 252-260, 341.
SHEN Hualei, SU Xinqi, ZHAO Qiaoli, et al. Extraction of lodging area of wheat varieties by unmanned aerial vehicle remote sensing based on deep learning[J]. Transactions of the Chinese society for Agricultural Machinery, 2022, 53(9): 252-260, 341. (in Chinese)

[10] ZHOU Y, FU C J, ZHAI Y T, et al. Identification of rice leaf disease using improved ShuffleNet V2 [J]. Computers Materials & Continua, 2023, 75(2): 4501-4517.

[11] 王忠培, 谢成军, 董伟, 等. 基于多维间注意力机制的水稻病害识别模型[J]. 江苏农业学报, 2024, 40(4): 625-635.
WANG Zhongpei, XIE Chengjun, DONG Wei, et al. Rice disease identification model based on multi-dimensional attention mechanism[J]. Jiangsu Journal of Agricultural Sciences, 2024, 40(4): 625-635. (in Chinese)

[12] QUYNH A N, QUOC K N, NGOC H T, et al. Using optimization algorithms to improve the classification of diseases on rice leaf of EfficientNet-B4 model [C]// Proceedings of 2023 8th International Conference on Intelligent Information Technology (ICIIT 2023), 2023: 209-215.

[13] 袁培森, 欧阳柳江, 翟肇裕, 等. 基于MobileNetV3Small-ECA的水稻病害轻量级识别研究[J]. 农业机械学报, 2024, 55(1): 253-262.
YUAN Peisen, OUYANG Liujiang, ZHAI Zhaoyu, et al. Lightweight identification of rice diseases based on improved ECA and MobileNetV3Small[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(1): 253-262. (in Chinese)

[14] 崔金荣, 魏文钊, 赵敏. 基于改进MobileNetV3的水稻病害识别模型[J]. 农业机械学报, 2023, 54(11): 217-224, 276.
CUI Jinrong, WEI Wenzhao, ZHAO Min. Rice disease identification model based on improved MobileNetV3[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 217-224, 276. (in Chinese)

[15] BARI B S, ISLAM M N, RASHID M, et al. A real-time approach of diagnosing rice leaf disease using deep learning-based Faster R-CNN framework[J]. Peerj Computer Science, 2021, 7: e432.

[16] PAN J C, WANG T Y, WU Q F. RiceNet: a two stage machine learning method for rice disease identification [J]. Biosystems Engineering, 2023, 225: 25-40.

[17] 廖娟, 刘凯旋, 杨玉青, 等. 基于RDN-YOLO的自然环境下水稻病害识别模型研究[J]. 农业机械学报, 2024, 55(8): 233-242.
LIAO Juan, LIU Kaixuan, YANG Yuqing, et al. Rice disease recognition in natural environment based on RDN-YOLO[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(8): 233-242. (in Chinese)

[18] 杨波, 何金平, 张立娜. 基于改进SPP-x的YOLOv5神经网络水稻叶片病害识别检测[J]. 中国农机化学报, 2023, 44(9): 190-197.
YANG Bo, HE Jinpin, ZHANG Li'na. Identification and detection of rice leaf diseases by YOLOv5 neural network based on improved SPP—x[J]. Journal of Chinese Agricultural Mechanization, 2023, 44(9): 190-197. (in Chinese)

[19] KIM Y H, PARK K R. MTS-CNN: multi-task semantic segmentation-convolutional neural network for detecting crops and weeds [J]. Computers And Electronics In Agriculture, 2022, 199: 107146.

[20] PENG H X, LI Z H, ZHOU Z Y, et al. Weed detection in paddy field using an improved RetinaNet network [J]. Computers and

Electronics in Agriculture, 2022, 199: 107179.

[21] 曹英丽, 赵雨薇, 杨璐璐, 等. 基于改进DeepLabv3+的水稻田间杂草识别方法[J]. 农业机械学报, 2023, 54(12): 242-252.
CAO Yingli, ZHAO Yuwei, YANG Lulu, et al. Weed identification method in rice field based on improved DeepLabv3+[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(12): 242-252. (in Chinese)

[22] 亢洁, 刘港, 郭国法. 基于多尺度融合模块和特征增强的杂草检测方法[J]. 农业机械学报, 2022, 53(4): 254-260.
KANG Jie, LIU Gang, GUO Guofa, et al. Weed detection based on multi-scale fusion module and feature enhancement[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(4): 254-260. (in Chinese)

[23] 王秀红, 王庆杰, 李洪文, 等. 基于YOLO v5-Jetson TX2的秸秆覆盖农田杂草检测方法[J]. 农业机械学报, 2023, 54(11): 39-48.
WANG Xiuhong, WANG Qinjie, LI Hongwen, et al. Weed detection method of straw-covered farmland based on YOLO v5-Jetson TX2[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 39-48. (in Chinese)

[24] 刘莫尘, 高甜甜, 马宗旭, 等. 基于MSRCR-YOLOv4-tiny的田间玉米杂草检测模型[J]. 农业机械学报, 2022, 53(2): 246-255, 335.
LIU Mochen, GAO Tiantian, MA Zhongxu, et al. Target detection model of corn weeds in field environment based on MSRCR algorithm and YOLOv4-tiny[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2): 246-255, 335. (in Chinese)

[25] 亢洁, 刘港, 王勍, 等. 基于动态剪枝神经网络的杂草检测算法研究[J]. 农业机械学报, 2023, 54(4): 268-275.
KANG Jie, LIU Gang, WANG Qing, et al. Weed detection algorithm based on dynamic pruning neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(4): 268-275. (in Chinese)

[26] REN J J, HU X W, ZHU L, et al. Deep texture-aware features for camouflaged object detection[J]. IEEE Transactions on Circuits and Systems For Video Technology, 2023, 33(3): 1157-1167.

[27] ZHOU X, WANG D, KRÄHENBÜHL P. Objects as points[J]. ArXiv, 2019, abs/1904.07850.

[28] ZHOU X, KOLTUN V, KRÄHENBÜHL P. Probabilistic two-stage detection[J]. ArXiv, 2021, abs/2103.07461.

[29] REZATOFIGHI H, TSOI N, GWAK J, et al. Generalized intersection over union: a metric and a loss for bounding box regression[C]// 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR 2019), 2019: 658-666.

[30] 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.

[31] TIAN Z, SHEN C, CHEN H, et al. FCOS: fully convolutional one-stage object detection. arXiv 2019[J]. arXiv Preprint, arXiv: 1904.01355, 2019.

[32] GE Z, LIU S, WANG F, et al. YOLOX: exceeding YOLO series in 2021[J]. ArXiv, 2021. abs/2107.08430.

[33] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers[C]// Proceedings of the Computer Vision - ECCV, 2020.