

doi:10.6041/j.issn.1000-1298.2021.12.025

基于改进 CenterNet 的小麦条锈病菌夏孢子自动检测方法

雷雨^{1,2} 周晋兵^{1,2} 何东健^{3,4} 陈鹏^{1,2} 曾伟辉^{1,2} 梁栋^{1,2}

(1. 安徽大学农业生态大数据分析与应用技术国家地方联合工程研究中心, 合肥 230601; 2. 安徽大学互联网学院, 合肥 230601; 3. 西北农林科技大学机械与电子工程学院, 陕西杨凌 712100; 4. 农业农村部农业物联网重点实验室, 陕西杨凌 712100)

摘要: 针对孢子捕捉设备采集的显微图像中真菌夏孢子自动检测存在严重的误检和漏检问题, 提出一种基于改进 CenterNet 的小麦条锈病菌夏孢子自动检测方法。首先, 针对夏孢子显微图像孢子目标微小、种类少等特点, 通过减半 Basic Block 层数, 优化 CenterNet 网络中的特征提取网络, 提高了检测和训练速度, 降低了误检率; 其次, 根据孢子形态为近椭圆或圆形的特点, 将原始用于 CenterNet 训练的目标长宽, 改进为目标的椭圆框长短轴长度和角度, 提高了孢子分割重合率; 最后, 提出使用椭圆的长短轴映射矩形来计算椭圆框热图的高斯核半径, 以减少孢子的漏检率。实验结果表明, 改进的 CenterNet 夏孢子检测方法对小麦条锈病菌夏孢子检测的识别精确率达到了 98.77%, 重叠度为 83.63%, 检测速度为 41 f/s, 达到了实时检测的应用需求, 比原始的 CenterNet 模型重叠度提高了 7.53 个百分点, 检测速度快 11 f/s, 模型占用内存降低了 68.5%。本文方法能够精准检测并分割出显微图像中的夏孢子, 可为农田空气中小麦条锈病菌夏孢子的自动检测及条锈病的早期预防控制提供技术支持。

关键词: 小麦条锈病; 真菌夏孢子; 自动检测; 改进 CenterNet; 深度学习; 椭圆框

中图分类号: S435.121.4⁺2; TP391.4 文献标识码: A 文章编号: 1000-1298(2021)12-0233-09

OSID:



Automatic Detection Method for Urediniospores of Wheat Stripe Rust Based on Improved CenterNet Model

LEI Yu^{1,2} ZHOU Jinbing^{1,2} HE Dongjian^{3,4} CHEN Peng^{1,2} ZENG Weihui^{1,2} LIANG Dong^{1,2}

(1. National Engineering Research Center for Agro-Ecological Big Data Analysis and Application, Anhui University, Hefei 230601, China

2. School of Internet, Anhui University, Hefei 230601, China

3. College of Mechanical and Electronic Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China

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

Abstract: An automatic detection method for urediniospores of wheat stripe rust based on improved CenterNet model was proposed to solve the serious problems of false detection and missing detection in microscopic images collected by spore capture equipment. Firstly, the feature extraction network in CenterNet was optimized by halving the number of Basic Block layers to improve detection and training speed in view of the characteristics of small spore targets and few species in fungal spore microscopic images. Secondly, according to the characteristic that the spore shape was nearly elliptic or round, the width and height of the target originally used for training was improved into the long and short axis and angle of the target ellipse frame for the training part of CenterNet, which improved the spore segmentation coincidence rate. Finally, the long and short axis mapping rectangle was used to calculate the Gaussian core radius of the elliptical frame heat map to reduce the missed detection rate of spores. The experimental results showed that the identification accuracy of the improved CenterNet detection method for urediniospores of wheat stripe rust was 98.77%, the overlap degree was 83.63%, and the detection speed was 41 f/s, which met the application requirements of real-time detection. Compared with the original CenterNet model, the overlap degree was increased by 7.53 percentage points, the detection speed was 11 f/s faster, and the model size was reduced by 68.5%. In conclusion, the experimental

收稿日期: 2021-09-12 修回日期: 2021-10-13

基金项目: 国家自然科学基金项目(62072002)、安徽省科技重大专项(202003a06020016)、安徽省自然科学基金项目(2108085MC95)和农业生态大数据分析与应用技术国家地方联合工程研究中心开放项目(AE2018009)

作者简介: 雷雨(1990—),男,讲师,博士,主要从事计算机视觉及农业信息技术研究,E-mail: leiyu@ahu.edu.cn

通信作者: 陈鹏(1978—),男,教授,博士生导师,主要从事机器视觉、智慧机器人应用及农业信息技术研究,E-mail: pchen@ahu.edu.cn

results indicated that the proposed method can accurately detect and segment fungal spores in the microscopic image, providing technical support for the automatic detection of airborne urediniospores of wheat stripe rust in wheat fields and the early control of wheat stripe rust.

Key words: wheat stripe rust; fungal urediniospores; automatic detection; improved CenterNet; deep learning; elliptical bounding box

0 引言

条锈病是小麦最主要病害之一^[1],常年在我国西北、西南、华北、长江中下游等冬麦区和西北春麦区广泛流行,该病会引起小麦大幅减产,甚至绝收,对小麦安全生产具有重大威胁^[2]。小麦条锈病是由条形柄锈菌(*Puccinia striiformis* f. sp. *tritici*)^[3]引起,其发病具有分布广、流行性强、危害大等特点。首先在田间出现条锈菌源中心,然后借助气流由发病中心向周边扩散感染,以条锈病原真菌夏孢子的形态在异地越夏和越冬,完成条锈病害的周年循环,并在不同区域往返流行传染^[4-6]。因此,快速准确地检测出田间空气中真菌夏孢子数量,可加强对小麦条锈病的早期预测预报,对于减少经济损失、控制农药滥用、保证粮食安全具有重要意义。

随着计算机视觉技术的发展,国内外学者对真菌孢子识别已经取得了一定的进展^[7-9]。李小龙等^[10]对小麦条锈病菌夏孢子显微图像进行基于最近邻插值法的缩放处理、基于 K-means 聚类算法的分割处理、形态学操作修饰和分水岭分割等处理,实现了夏孢子的自动计数,但当孢子大面积重叠时,算法效率会降低。齐龙等^[11]通过分块背景提取法校正光照,根据 Canny 算子进行边缘检测,利用椭圆度、复杂度和最小外接矩阵宽度等形态学特征进行分类,最后利用距离变换和改进的分水岭算法对粘连孢子进行检测,准确度达到了 98.5%,但特征提取过程较复杂。王震等^[12]通过提取孢子图像的梯度方向直方图特征(HOG 特征)作为输入向量,提出了一种加性交叉核支持向量机(IXSVM)的稻瘟病孢子检测方法,实现了 98.2% 的检测率,但平均检测耗时需 5.5 s。上述研究表明,使用传统机器视觉方法检测孢子,需预先针对孢子图像提取目标特征,然后采用算法进行目标拟合和检测,其特征提取过程较繁杂,费时费力。近年来,随着深度学习算法不断改进和计算机算力提高,深度学习在农业领域得到广泛应用^[13-14]。LIANG 等^[15]对小麦白粉病孢子采用改进 U-Net 网络进行图像分割,分割率达到了 91.4%。姚青等^[16]基于改进 CornerNet 自动检测方法,实现了对 2 种稻飞虱检测,平均精确度为 95.53%。杨蜀秦等^[17]基于改进 CenterNet 模型对

无人机遥感影像的玉米雄蕊识别精度达到了 92.4%,检测速度达到了 36 f/s。目前国内外学者采用深度学习检测真菌孢子类的研究较少,大部分研究是基于 Anchor(锚框)的农作物和病虫害目标检测,该类方法虽能满足实时检测要求,但需预置锚框的尺寸、比例,大量的锚框会导致运算复杂度高,影响训练的效率。当前以 CornerNet^[18]、CenterNet^[19]为代表的基于 Anchor-Free 的模型应用较为广泛,其中,CenterNet 模型具有扩展性强、推理速度快以及检测精度高等优点,在快速检测的同时识别准确率高,具有复杂背景下微小夏孢子实时检测识别的潜力。

针对显微图像中小麦条锈病菌夏孢子自动检测存在严重的误检和漏检问题,本文拟通过优化特征提取网络提取目标特征,减少网络参数防止过拟合,同时改进 CenterNet 检测框为带角度的椭圆框以增强分割重叠度,提出一种基于改进 CenterNet 模型的小麦条锈病菌夏孢子自动检测方法。

1 材料与方法

1.1 孢子显微图像采集

本研究供试小麦条锈病菌夏孢子于西北农林科技大学小麦抗病种质资源创制与利用研究中心东南窑低温温室内繁育,真菌孢子显微图像采用文献[20]中的小麦条锈病菌夏孢子显微图像远程采集设备采集,设备可自动完成取载玻片、涂脂、空中孢子捕捉、孢子显微图像采集、载玻片回收等一系列功能,能够远程实时采集放大 400 倍的夏孢子显微图像。在实验室条件下,用洗耳球在采集设备进气口上方缓慢持续吹起新鲜的小麦条锈病菌夏孢子,使孢子扩散到空气中,由机体内置风扇使捕捉仓内形成负压,将上方夹带着孢子的空气从上到下垂直抽入仓内粘附在载玻片上,根据矩形点阵式采集方法,设备通过驱动模块输出不同的脉冲数在载玻片中间 50 cm × 25 cm 区域完成孢子显微图像的采集,分辨率为 1 024 像素 × 822 像素, BMP 格式,所采集的部分供试夏孢子原始图像如图 1 所示。

由图 1 可以看出:①夏孢子外形似椭圆,个体小且大小不一。②夏孢子相互粘连现象严重。③由于涂抹凡士林出现的晶体状杂质和空气中灰尘影响,

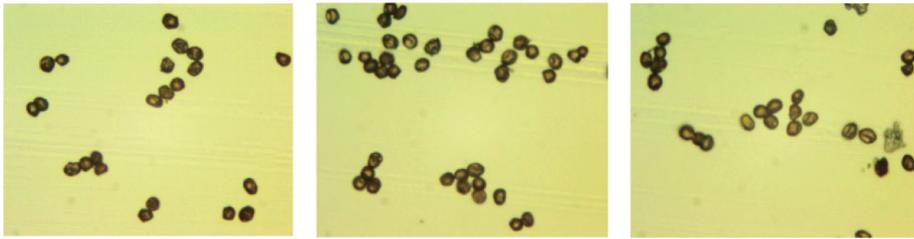


图 1 小麦条锈病菌夏孢子原始图像

Fig. 1 Original images of urediospores of *Puccinia striiformis* f. sp. *tritici*

图像中存在晶体状杂质和灰尘。上述夏孢子图像特点为真菌孢子自动检测增加了难度。获得的原始孢子显微图像经过人工挑选和预处理后,共获得数据集 21 420 幅。由于经预处理的图像边缘会超出原始图像,因此,在边缘填充与凡士林颜色相近的背景,并将图像分辨率修改为 1 366 像素 × 1 366 像素, jpg 格式。

1.2 数据集构建与处理

通过统计,每幅图像中存在 1 ~ 50 个夏孢子。当孢子数量增多,大量孢子密集粘连,若使用矩形框标注数据,会导致框间重复交叠,影响检测效果。因此,本文使用椭圆框标注数据集,以减少背景对分割效果的影响。经人工使用带角度的椭圆框进行标注,使用 18 000 幅用于训练,按照 8:2 划分为训练集与验证集,剩余 3 420 幅作为测试集。由于使用 Via 2.0 标注的 COCO 类型数据集未保存物体的长短轴长度和角度,因此需对标注数据进行预处理。使用保存数据的 144 个离散点,计算出椭圆的长短轴长度和旋转角度,最终得到标注数据格式为 $\text{bbox}[x, y, 2a, 2b, \text{angle}]$ 。 x 和 y 为椭圆中心点坐标, $2a$ 和 $2b$ 为长短轴长度, angle 为长轴相对于 X 轴正方向的角度,范围是 $0^\circ \sim 180^\circ$ 。

2 CenterNet 模型构建与改进

近年来,深度学习已在农作物识别和病害检测等方面获得了较好的效果^[13,21-23]。基于 CenterNet 模型^[19]具有检测速度快、识别精度高以及泛化能力强等优点,具有快速识别孢子的潜力。夏孢子形态学特征为近椭圆或圆形,且孢子易粘连在一起,使用传统机器视觉方法进行粘连分割难度较大。基于此,本文选择 CenterNet 模型进行孢子自动检测方法的研究。

2.1 基于改进 CenterNet 的孢子检测网络

CenterNet^[19]是无锚框模型目标检测算法的典型代表,与 CornerNet^[18](检测左上角点和右下角点)和 ExtremeNet^[24](检测最上、最下、最左、最右、中心点)类似,CenterNet 通过检测物体的中心点和长宽来确定检测框的位置、尺寸。模型结构主要包

括特征提取网络和预测头 2 个模块。第 1 模块的特征提取网络负责提取特征生成特征图,第 2 模块的预测头部分用来预测目标的热图、中心点偏置和预测框的长宽。CenterNet 模型将目标检测问题转换为检测目标中心点问题,检测时通过特征提取网络输出的特征图经过预测头得出检测目标的中心点位置,并通过偏置量微调中心点的位置,使预测的中心点位置更加准确。

直接将原始 CenterNet 模型用于检测小麦条锈病菌夏孢子图像,易出现目标孢子的误检和漏检问题。针对误检问题,本研究采用简化网络结构的方式构建了参数更少的特征提取网络 ResNet10,减少模型的过拟合,降低了误检率;针对漏检问题,将原始的矩形检测框改进为带角度的椭圆检测框,同时,使用映射矩形计算出热图的高斯核半径,减少检测框中的无效背景,提高了模型检测的精确率与分割度。改进后的小麦条锈病菌夏孢子 CenterNet 检测模型网络框架如图 2 所示,图中 W 为输入图像的宽度, H 为输入图像的高度。

2.2 特征提取网络的改进

特征提取网络是目标检测中的重要一环,目标检测模型的检测精度、速度等直接受到特征提取网络的影响。原始 CenterNet 模型的特征提取网络有很多,一般选择 Hourglass Net^[25]、DLANet^[26]或 ResNet^[27]等。这些网络主要用于提取输入图像的特征。

由于夏孢子显微图像的数据集数量不够庞大,且显微图像中有夏孢子目标尺寸较微小,孢子种类较少的特点,若使用结构参数量较大的 Hourglass Net 和 DLANet 网络提取特征,易导致模型过拟合;基于此,本研究基于 ResNet 网络结构,构建了参数更少的 ResNet10 网络作为改进 CenterNet 模型的特征提取网络结构,以降低夏孢子检测模型的过拟合,ResNet10 结构如图 3 所示。

从图 3 可看出,构建的 ResNet10 网络与现有的 ResNet18 的主要区别在于 Layer1 ~ Layer4 的 Basic Block 层数,在 ResNet18 中,这 4 个层的 Basic Block

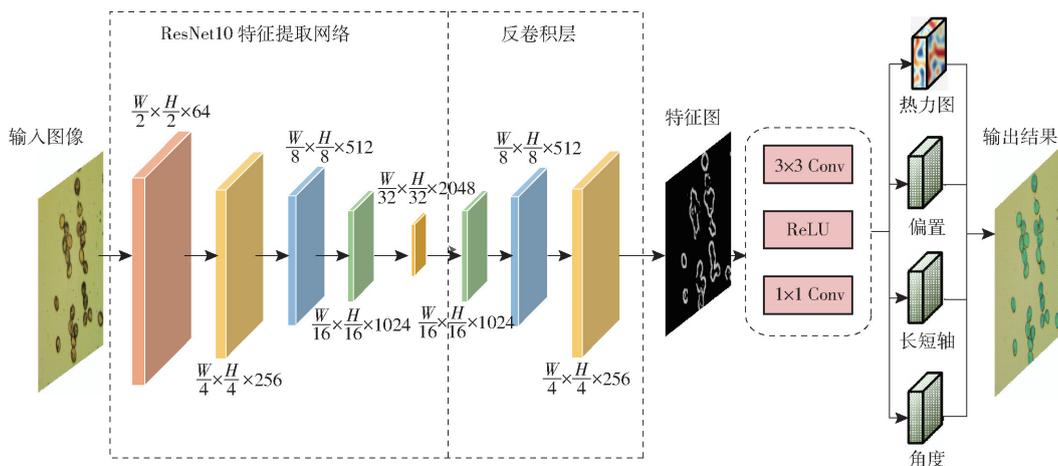


图2 基于改进 CenterNet 的真菌夏孢子检测模型网络框架

Fig.2 Network framework of urediniospores detection model based on improved CenterNet

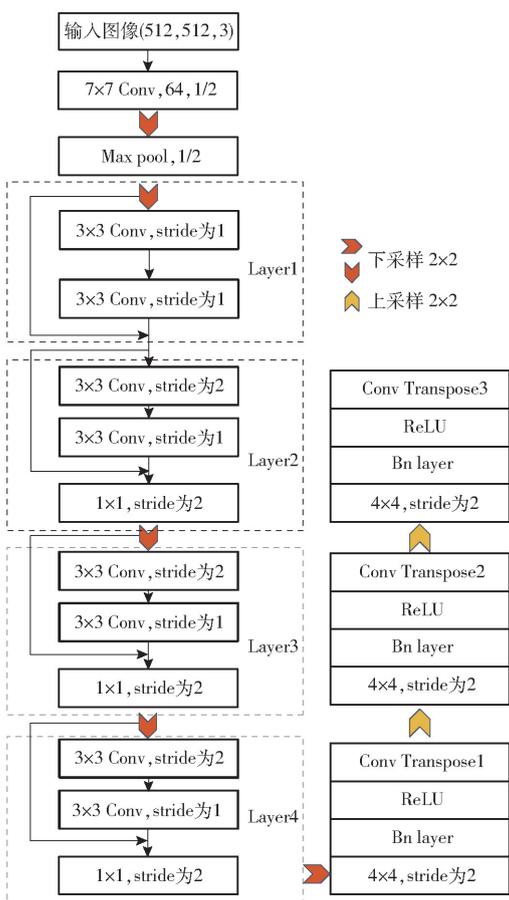


图3 ResNet10 结构

Fig.3 ResNet10 structure

数目均为 2,对于 ResNet10,层数均缩小为 $\frac{1}{2}$, Layer1 即是一个 Basic Block。在 Layer1 中,步长均为 1, Layer2 ~ Layer4 后均有一个步长为 2,卷积核为 1×1 的下采样卷积。下采样后的特征图再经过上采样得到高分辨率的特征图,最后使用 4 个预测头得出目标的中心位置、中心偏置、长短轴长度和角度。

2.3 损失函数设计

由于需要检测孢子的角度,在原始 CenterNet

损失函数的基础上,需添加角度损失 L_{ang} 进行训练。改进 CenterNet 模型的损失函数 L_{det} 由 4 部分组成: 热力图损失 $L_{heatmap}$ 、物体长短轴损失 L_{ab} 、中心偏置损失 L_{offset} 和角度损失 L_{ang} , 计算式为

$$L_{det} = \lambda_{heatmap} L_{heatmap} + \lambda_{ab} L_{ab} + \lambda_{offset} L_{offset} + \lambda_{ang} L_{ang} \quad (1)$$

式中 $\lambda_{heatmap}$ ——热图损失系数

λ_{ab} ——长短轴损失系数

λ_{offset} ——中心偏置损失系数

λ_{ang} ——角度损失系数

孢子长短轴损失和角度损失较大,因此 λ_{ab} 和 λ_{ang} 取值 0.1,其他损失值较小,因此系数 λ 均取 1。

$L_{heatmap}$ 使用改进的 Focal loss^[28] 损失

$$L_{heatmap} = \frac{1}{N} \sum_{xyc} \begin{cases} (1 - \hat{Y}_{xyc})^\alpha \ln \hat{Y}_{xyc} & (Y_{xyc} = 1) \\ (1 - Y_{xyc})^\beta (\hat{Y}_{xyc})^\alpha \ln(1 - \hat{Y}_{xyc}) & (Y_{xyc} \neq 1) \end{cases} \quad (2)$$

式中 N ——图像中关键点的数量

Y_{xyc}, \hat{Y}_{xyc} ——真实、预测孢子像素点 (x, y) 的置信度

α, β ——超参数,分别取 2 和 4

经下采样后,原始检测框的中心点会产生偏差,因此对每个中心点添加一个偏移损失 L_{offset}

$$L_{offset} = \frac{1}{N} \sum_p \left| \hat{O}_p - \left(\frac{p}{R} - \tilde{p} \right) \right| \quad (3)$$

式中 R ——下采样倍数

\tilde{p} ——预测中心点

p ——真实中心点

\hat{O}_p ——预测中心点的偏置

类似地, L_{ab} 和角度损失亦采用 L1 损失

$$L_{ab} = \frac{1}{N} \sum_{k=1}^N |\hat{S}_{p_k} - s_k| \quad (4)$$

式中 p_k ——检测框的中心点

\hat{S}_{p_k} ——网络预测的长短轴长度(或角度)

s_k ——检测框的长短轴长度(或角度)

2.4 Heatmap 高斯核半径计算方法

原始 CenterNet 模型训练过程中预测后的矩形框与人工标注的矩形框一般会出现 3 种位置关系, 如图 4 所示。

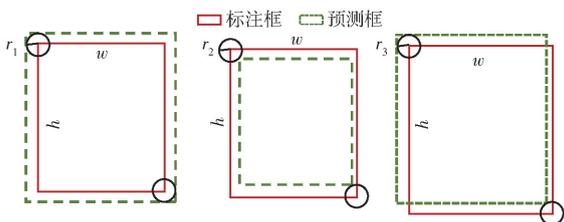


图 4 检测框与标注框的 3 种位置关系

Fig. 4 Three positional relationships between detection frame and annotation frame

从图 4 可看出, 3 种绿色的预测框均能很好地包围目标。所以, 为了能得到效果好的预测框, 需准确计算出图 4 中的半径 r (即高斯核半径)。Heatmap 热图^[29], 起初在人体关键点检测任务中得到应用, 后来在目标检测任务中表现出很好的性能。在 CenterNet 模型中, 可通过

$$Y_{xye} = \exp \left(- \frac{(x - \tilde{p}_x)^2 + (y - \tilde{p}_y)^2}{2\sigma_p^2} \right) \quad (5)$$

$(Y_{xye} \in [0, 1] \frac{W}{R} \times \frac{H}{R} \times C)$

式中 (x, y) ——图中点的坐标

$(\tilde{p}_x, \tilde{p}_y)$ ——孢子中心坐标

σ_p ——标准差 C ——类别数

将目标标注框中心点的关键信息散射到高斯核半径为 r 的热图上, 使得关键点的检测转换成可进行全卷积的热图, 最后通过热图、偏置和长宽信息得到预测结果。

对于矩形检测框, 最小高斯核半径 r 计算式为

$$r = \min(r_1, r_2, r_3) \quad (6)$$

其中

$$r_1 = \frac{-(w+h) + \sqrt{(w+h)^2 - 4(wh + \frac{1-I_{\text{overlap}}}{1+I_{\text{overlap}}})}}{2} \quad (7)$$

$$r_2 = \frac{-2(w+h) + \sqrt{4(w+h)^2 - 16(1-I_{\text{overlap}})wh}}{8} \quad (8)$$

$$r_3 = \frac{-2I_{\text{overlap}}(w+h) + \sqrt{[2I_{\text{overlap}}(w+h)]^2 - 16I_{\text{overlap}}(I_{\text{overlap}}-1)wh}}{8I_{\text{overlap}}} \quad (9)$$

式中 I_{overlap} ——真实框与标注框最小重叠度, 取 0.7

w ——矩形框宽 h ——矩形框高

由于本文使用椭圆检测框检测目标, 不能直接使用上述原始 CenterNet 模型的高斯核半径计算方法。因此, 本文提出使用图 5 中的 6 种方式将孢子的椭圆框映射成矩形框, 再通过式(6)~(9)间接计算出最小的高斯核半径 r 。当椭圆的角度为 0° 、 90° 和 180° 时, R5 取图 5b 红色矩形, 其余情况使用图 5a 方式计算。将椭圆框中心点的关键信息散射到高斯核半径为 r 的热图上, 最后通过热图、偏置、长短轴长度和角度信息得到预测结果。

- R1: 长短轴长度分别作为矩形的长和宽
- R2: 椭圆的外切长方形
- R3: 椭圆的长轴长度在 X 轴和 Y 轴上的投影分别作为长和宽
- R4: 长轴长度在 X 轴的映射作为长, 短轴长度在 Y 轴的映射作为宽
- R5: 短轴长度直接作为长和宽
- R6: 短轴长度在 X 轴和 Y 轴的投影作为长和宽

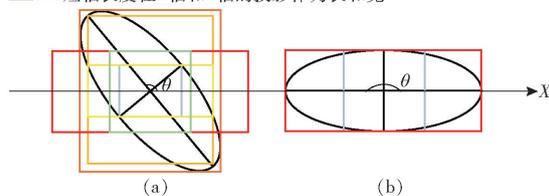


图 5 Heatmap 矩形映射

Fig. 5 Heatmap rectangle mapping

2.5 模型评价方法

目标检测领域的评价指标除使用平均精度均值 (Mean average precision, MAP) 以外, 对于图像分割, 还经常使用 COCO 数据集的评价指标平均交并比 (Mean intersection over union, MIOU)。对于原始 CenterNet 检测结果, 由于预测框均使用矩形, 计算 MIOU 较方便。但本文的检测框使用带角度的椭圆形检测框, 计算 MIOU 比较困难。因此, 本文使用蒙特卡洛计算方法。对于真实的椭圆标注框 R_{gt} 和预测框 R_{pre} , 生成随机 $N \times N$ 个坐标点, 统计落在 2 个框内的落点个数, 计算 IOU 的方法为

$$I_{IOU} = N_{\text{inter}} / (\text{Num}(R_{gt}) + \text{Num}(R_{pre}) - N_{\text{inter}}) \quad (10)$$

其中 $N_{\text{inter}} = \text{Num}(R_{gt} \& R_{pre})$ (11)

式中 I_{IOU} ——交并比 (IOU)

&——同时落在 2 个检测框的情况

N_{inter} ——同时落在 R_{gt} 和 R_{pre} 的数目

Num——计数函数

为更加全面地评估不同模型对孢子的检测精度, 还需使用精确率 (Precision)、召回率 (Recall) 与

F1 值作为评价指标。

2.6 模型训练环境与方法

所有网络均在同一硬件环境下训练,操作系统为 Windows 10,处理器为 AMD 3700X,显卡为 GPU1080Ti,显存 11 GB。训练使用 Pytorch 1.6 深度学习框架,图像为 21 420 幅,18 000 幅作为训练和验证集,按照 8:2 划分,剩余图像作为测试集。训练使用的样本批尺寸 (Batch size) 为 8,训练过程采用自适应矩估计 (Adaptive moment estimation, ADAM) 方法进行优化。训练共 20 个迭代周期 (Epoch),每个周期 1 800 次,共计迭代 3.6×10^5 次。训练学习率设为 1.25×10^{-4} ,权重衰减设为 0.000 1。

3 实验与结果分析

使用同一数据集分别使用不同特征提取网络 and 不同椭圆映射矩形,在相同模型训练环境和方法下进行相同批次训练,特征提取网络分别使用 ResNet10、ResNet18、ResNet34 和 ResNet50,椭圆映射矩形分别使用图 5 的 R1、R2、R3、R4、R5、R6 进行对比实验,实验对比结果如表 1、2 所示。

表 1 不同特征提取网络的精确率和召回率

Tab.1 Precision and recall of different feature extraction networks %

映射矩阵 编号	ResNet10		ResNet18		ResNet34		ResNet50	
	精确	召回	精确	召回	精确	召回	精确	召回
	率	率	率	率	率	率	率	率
R1	98.45	97.11	98.65	96.21	98.41	97.32	98.45	97.53
R2	98.28	97.28	98.40	96.60	97.76	96.51	98.24	97.57
R3	98.16	97.53	98.25	97.70	97.74	97.70	97.91	97.79
R4	98.49	97.11	98.49	97.11	97.90	97.15	98.46	97.83
R5	97.23	97.23	98.58	97.32	98.20	97.40	98.16	97.87
R6	97.93	96.81	97.95	97.57	97.89	96.55	98.58	97.57

表 2 不同特征提取网络的 F1 值和分割率

Tab.2 F1 value and segmentation rate of different feature extraction networks %

映射矩阵 编号	ResNet10		ResNet18		ResNet34		ResNet50	
	F1 值	分割						
		率		率		率		率
R1	97.77	83.73	97.41	82.98	97.86	83.32	97.99	84.92
R2	97.78	84.02	97.49	83.26	97.13	81.93	97.91	84.90
R3	97.84	83.68	97.97	84.14	97.72	83.63	97.85	84.83
R4	97.79	84.40	97.79	83.33	97.52	83.70	98.14	84.69
R5	97.23	84.26	97.94	83.05	97.80	83.49	98.02	84.79
R6	97.37	84.21	97.76	84.09	97.22	83.52	98.08	84.50

从表 1、2 中可看出,随着特征提取网络层数的增多,孢子的检测指标并未一直减小,使用 ResNet34 作为特征提取网络的模型综合性能最差。

当使用结构简单的 ResNet10 特征提取网络检测孢子图像,识别准确率未受到影响,网络的训练速度反而更快。使用 R1、R2、R3、R4 映射矩形计算高斯核半径时,ResNet10 的准确率与 ResNet18、ResNet50 接近,平均精确率优于 ResNet34 模型 0.40 个百分点。特征提取网络使用 ResNet10 网络时,高斯核半径计算方法使用 R1 和 R4 矩形的检测精确率较高,与 R5 矩形和 R6 矩形相比,检测精确率提高 0.56 ~ 1.26 个百分点。使用 R4 映射矩形计算高斯半径时 (特征提取网络使用 ResNet10 网络),取得的分割效果最好,优于 ResNet34 (使用 R2 映射矩形) 方法 2.47 个百分点,与 ResNet50 网络相近,但训练速率更快。因此,本文选择 ResNet10 网络作为改进 CenterNet 模型的特征提取网络,高斯核半径使用 R4 映射矩形计算,能够使用更少的参数训练网络,加快训练速率,并得到很好的检测效果。

在相同条件下,分别使用原始 CenterNet 模型 (特征提取网络使用 ResNet50) 与改进 CenterNet 模型 (高斯核半径计算使用 R4 矩形) 进行训练,实验对比数据如表 3 所示,检测结果如图 6 所示。

表 3 2 种算法对不同密度孢子的检测结果对比

Tab.3 Comparison of detection results of two algorithms for spores with different densities

孢子数量	算法	精确率/ 召回率/ 重叠度/ 检测速率/			
		%	%	%	(f·s ⁻¹)
0 ~ 10	原始 CenterNet	100	100	76.21	30
	改进 CenterNet	100	100	84.09	42
10 ~ 30	原始 CenterNet	96.86	94.92	76.15	30
	改进 CenterNet	97.43	96.38	83.58	41
> 30	原始 CenterNet	98.77	98.87	75.94	30
	改进 CenterNet	98.87	97.54	83.23	40
平均值	原始 CenterNet	98.54	97.93	76.10	30
	改进 CenterNet	98.77	97.97	83.63	41

从表 3 可以看出,随着孢子数量的增多,原始 CenterNet 算法和改进 CenterNet 算法的精确率和召回率均减小。当孢子数量在 10 ~ 30 时,原始 CenterNet 算法的精确率下降了 3.14 个百分点,召回率下降了 5.08 个百分点。改进 CenterNet 算法的精确率下降了 2.57 个百分点,召回率下降了 3.62 个百分点。随着孢子数量的增多,原始 CenterNet 算法容易受粘连孢子的影响导致多孢一框及漏检的现象,对粘连孢子的检测精度明显下降。而改进 CenterNet 算法使用椭圆框分割孢子,减少了检测框中的无效背景,能够预测更精确的检测框,在粘连孢子的检测上取得了较好的检测效果。改进 CenterNet 模型的识别精确率达到了 98.77%,重叠度为 83.63%,检测速度为 41 f/s,与原始的

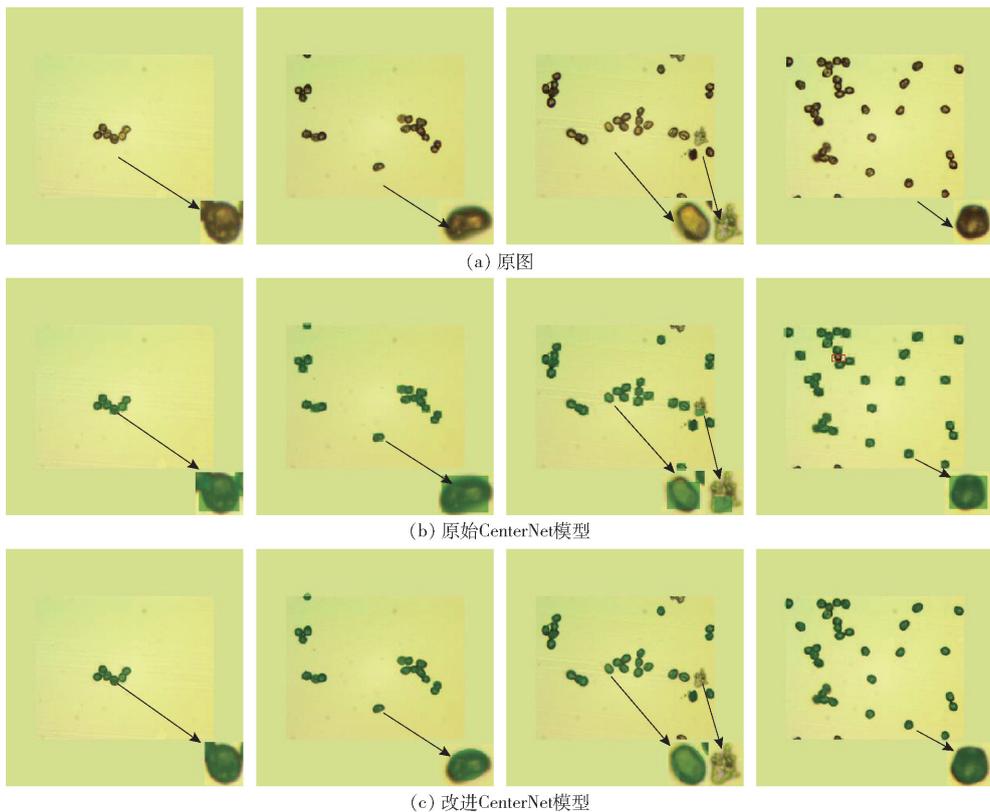


图 6 原始 CenterNet 和改进 CenterNet 检测结果对比

Fig. 6 Comparison of CenterNet and improved CenterNet experiment results

CenterNet 模型相比,识别精确率提高 0.23 个百分点,重叠度提高 7.53 个百分点,检测速度加快 11 f/s。此外,同等条件下,以 ResNet10 作为特征提取网络的改进 CenterNet 模型占用内存为 43.8 MB,是原始 CenterNet 模型的 31.5%,模型占用内存降低了 68.5%,更易于部署到服务器或远程设备上。因此,本文提出的改进 CenterNet 模型,能够满足小麦条锈病菌夏孢子自动检测的应用要求,与原始 CenterNet 模型相比,在同等条件下,改进 CenterNet 模型能够取得更高的识别精度和更快的检测速度,并获得更高的分割率,减少误检率和漏检率。

从图 6 可以看出,在孢子数量较少的情况下,2 种方法均能检测出所有孢子。但当孢子数目增多到 10 个以上时,原始 CenterNet 模型出现了漏检的现象,如图 6b 第 4 幅图红框所示,这是由于孢子的密度增大、孢子粘连与重叠增加了模型识别的难度。此外,由于孢子图像中会存在一些杂质(灰尘等),在原始 CentetNet 模型检测结果中出现了误检的现象,如图 6b 第 3 幅图所示。由于改进 CenterNet 模型的检测框是带角度的椭圆框,更加贴合孢子的形状,在框中出现的背景更少。改进 CenterNet 模型可显著地关注孢子区域,并减少背景区域,在保证检测精准率的前提下,获得更高的孢子检测分割率。因此,本文使用的改进 CenterNet 模型的椭圆框检测方

法效果优于原始 CenterNet 模型,出现误检和漏检的概率更低。

4 结论

(1)为解决小麦条锈病菌夏孢子自动检测存在严重的误检和漏检问题,以实现快速、准确地检测真菌夏孢子,本研究根据孢子形态学特点,从特征提取网络、检测框和热图高斯核半径计算 3 方面改进了 CenterNet 模型。首先基于 ResNet18 网络,减半网络中的 Basic Block 层数,构建孢子特征提取网络 ResNet10,其次将 CenterNet 模型的矩形检测框改进为带角度的椭圆检测框以增强分割重叠度,最后使用椭圆映射矩形计算出热图的高斯核半径,最终提出了一种基于改进 CenterNet 模型的小麦条锈病菌夏孢子自动检测方法。

(2)在测试集上的实验表明,改进后的 CenterNet 模型的识别精确率达到了 98.77%,重叠度为 83.63%,检测速度为 41 f/s,达到了实时检测的应用需求,比原始 CenterNet 模型平均重叠度提高了 7.53 个百分点,检测速度快了 11 f/s,模型占用内存降低了 68.5%,使得改进模型更易于部署到服务器或者远程设备上。因此,本文提出的基于改进 CenterNet 的真菌孢子检测模型可以为小麦条锈病害检测提供一种有效的方法支持。

参 考 文 献

- [1] 马占鸿. 中国小麦条锈病研究与防控[J]. 植物保护学报, 2018, 45(1): 1-6.
MA Zhanhong. Researches and control of wheat stripe rust in China[J]. Journal of Plant Protection, 2018, 45(1): 1-6. (in Chinese)
- [2] 陈万权, 康振生, 马占鸿, 等. 中国小麦条锈病综合治理理论与实践[J]. 中国农业科学, 2013, 46(20): 4254-4262.
CHEN Wanquan, KANG Zhensheng, MA Zhanhong, et al. Integrated management of wheat stripe rust caused by *Puccinia striiformis* f. sp. *tritici* in China[J]. Scientia Agricultura Sinica, 2013, 46(20): 4254-4262. (in Chinese)
- [3] CHEN X M. Pathogens which threaten food security: *Puccinia striiformis*, the wheat stripe rust pathogen[J]. Food Security, 2020, 12(2): 239-251.
- [4] XU X M, MA L J, HU X P. Overwintering of wheat stripe rust under field conditions in the northwestern regions of China[J]. Plant Disease, 2019, 103(4): 638-644.
- [5] LI M J, ZHANG Y H, CHEN W Q, et al. Evidence for Yunnan as the major origin center of the dominant wheat fungal pathogen *Puccinia striiformis* f. sp. *tritici*[J]. Australasian Plant Pathology, 2021, 50(2): 241-252.
- [6] HU X P, CAO S Q, CORNELIUS A, et al. Predicting overwintering of wheat stripe rust in central and Northwestern China[J]. Plant Disease, 2020, 104(1): 44-51.
- [7] 林晓燕, 刘文耀, 陈晓冬, 等. 杨树病害孢子的图像识别技术研究[J]. 仪器仪表学报, 2003, 24(4): 364-366.
LIN Xiaoyan, LIU Wenyao, CHEN Xiaodong, et al. Spore image recognition of polar disease[J]. Chinese Journal of Scientific Instrument, 2003, 24(4): 364-366. (in Chinese)
- [8] LI X L, MA Z H, BIENVENIDO F, et al. Development of automatic counting system for urediospores of wheat stripe rust based on image processing[J]. International Journal of Agricultural and Biological Engineering, 2017, 10(5): 134-143.
- [9] LEI Y, YAO Z, HE D. Automatic detection and counting of urediospores of *Puccinia striiformis* f. sp. *tritici* using spore traps and image processing[J/OL]. Scientific Reports, 2018, 8. <https://doi.org/10.1038/s41598-018-31899-0>.
- [10] 李小龙, 马占鸿, 孙振宇, 等. 基于图像处理的小麦条锈病菌夏孢子模拟捕捉的自动计数[J]. 农业工程学报, 2013, 29(2): 199-206, 302.
LI Xiaolong, MA Zhanhong, SUN Zhenyu, et al. Automatic counting for trapped urediospores of *Puccinia striiformis* f. sp. *tritici* based on image processing[J]. Transactions of the CASE, 2013, 29(2): 199-206, 302. (in Chinese)
- [11] 齐龙, 蒋郁, 李泽华, 等. 基于显微图像处理的水稻瘟病菌孢子自动检测与计数方法[J]. 农业工程学报, 2015, 31(12): 186-193.
QI Long, JIANG Yu, LI Zehua, et al. Automatic detection and counting method for spores of rice blast based on micro image processing[J]. Transactions of the CASE, 2015, 31(12): 186-193. (in Chinese)
- [12] 王震, 褚桂坤, 王金星, 等. 基于HOG特征的IKSVM稻瘟病孢子检测[J/OL]. 农业机械学报, 2018, 49(增刊): 387-392.
WANG Zhen, CHU Guikun, WANG Jinxing, et al. Spores detection of rice blast by IKSVM based on HOG features[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(Supp.): 387-392. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=2018s052&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2018.50.052. (in Chinese)
- [13] 孙红, 李松, 李民赞, 等. 农业信息成像感知与深度学习应用研究进展[J/OL]. 农业机械学报, 2020, 51(5): 1-17.
SUN Hong, LI Song, LI Minzan, et al. Research progress of image sensing and deep learning in agriculture[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(5): 1-17. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20200501&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2020.05.001. (in Chinese)
- [14] 徐焕良, 孙云晓, 曹雪莲, 等. 基于光子传输模拟的苹果品质检测研究[J/OL]. 农业机械学报, 2021, 52(8): 338-345.
XU Huanliang, SUN Yunxiao, CAO Xuelian, et al. Apple quality detection based on photon transmission simulation[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(8): 338-345. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20210835&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2021.08.035. (in Chinese)
- [15] LIANG X, XINSHEN L, BOTAO W. Wheat powdery mildew spore images segmentation based on U-Net[J]. Journal of Physics: Conference Series, 2020, 1631:012074.
- [16] 姚青, 吴叔珍, 蒯乃阳, 等. 基于改进 CornerNet 的水稻灯诱飞虱自动检测方法构建与验证[J]. 农业工程学报, 2021, 37(7): 183-189.
YAO Qing, WU Shuzhen, KUAI Naiyang, et al. Automatic detection of rice planthoppers through light-trap insect images using improved CornerNet[J]. Transactions of the CSAE, 2021, 37(7): 183-189. (in Chinese)
- [17] 杨蜀秦, 刘江川, 徐可可, 等. 基于 CenterNet 的无人机遥感图像玉米雄蕊识别[J/OL]. 农业机械学报, 2021, 52(9): 206-212.
YANG Shuqin, LIU Jiangchuan, XU Keke, et al. CenterNet based maize tassel recognition for UAV remote sensing image[J/OL].

- OL]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(9): 206 – 212. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 20210924&journal_id = jcsam. DOI: 10. 6041/j. issn. 1000-1298. 2021. 09. 024. (in Chinese)
- [18] LAW H, DENG J. CornerNet: detecting objects as paired keypoints [C] // Proceedings of the European Conference on Computer Vision, 2018: 734 – 750.
- [19] ZHOU X, WANG D, KRÄHENBÜHL P. Objects as points[J]. arXiv preprint arXiv, 2019: 1904.07850v07852.
- [20] 雷雨, 姚志凤, 何东健. 小麦条锈病菌夏孢子显微图像远程采集系统设计与试验[J/OL]. 农业机械学报, 2018, 49(11): 39 – 47.
- LEI Yu, YAO Zhifeng, HE Dongjian. Design and experiment of micro-image remote acquisition system of uredinispores of *Puccinia striiformis* f. sp. *Tritici*[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(11): 39 – 47. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 20181105&journal_id = jcsam. DOI: 10. 6041/j. issn. 1000-1298. 2018. 11. 005. (in Chinese)
- [21] 赵德安, 吴任迪, 刘晓洋, 等. 基于 YOLO 深度卷积神经网络的复杂背景下机器人采摘苹果定位[J]. 农业工程学报, 2019, 35(3): 164 – 173.
- ZHAO Dean, WU Rendi, LIU Xiaoyang, et al. Apple positioning based on YOLO deep convolutional neural network for picking robot in complex background[J]. Transactions of the CSAE, 2019, 35(3): 164 – 173. (in Chinese)
- [22] 刘天真, 滕桂法, 苑迎春, 等. 基于改进 YOLO v3 的自然场景下冬枣果实识别方法[J/OL]. 农业机械学报, 2021, 52(5): 17 – 25.
- LIU Tianzhen, TENG Guifa, YUAN Yingchun, et al. Winter jujube fruit recognition method based on improved YOLO v3 under natural scene[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(5): 17 – 25. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 20210502&journal_id = jcsam. DOI: 10. 6041/j. issn. 1000-1298. 2021. 05. 002. (in Chinese)
- [23] 刘芳, 刘玉坤, 林森, 等. 基于改进型 YOLO 的复杂环境下番茄果实快速识别方法[J/OL]. 农业机械学报, 2020, 51(6): 229 – 237.
- LIU Fang, LIU Yukun, LIN Sen, et al. Fast recognition method for tomatoes under complex environments based on improved YOLO[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(6): 229 – 237. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 20200624&journal_id = jcsam. DOI: 10. 6041/j. issn. 1000-1298. 2020. 06. 024. (in Chinese)
- [24] ZHOU X, ZHUO J, KRÄHENBÜHL P. Bottom-up object detection by grouping extreme and center points [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2019: 850 – 859.
- [25] NEWELL A, YANG K, DENG J. Stacked hourglass networks for human pose estimation [C] // Proceedings of the European Conference on Computer Vision, 2016: 483 – 499.
- [26] YU F, WANG D, SHELHAMER E, et al. Deep layer aggregation [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 2403 – 2412.
- [27] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770 – 778.
- [28] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C] // Proceedings of the IEEE International Conference on Computer Vision, 2017: 2999 – 3007 .
- [29] CAO Z, HIDALGO G, SIMON T, et al. Realtime multi-person 2D pose estimation using part affinity fields [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1302 – 1310.