

doi:10.6041/j.issn.1000-1298.2021.S0.008

基于改进 YOLO v3 – tiny 的全景图像农田障碍物检测

陈斌¹ 张漫¹ 徐弘祯² 李寒² 尹彦鑫³

(1. 中国农业大学现代精细农业系统集成研究教育部重点实验室, 北京 100083;
 2. 中国农业大学农业农村部农业信息获取技术重点实验室, 北京 100083;
 3. 国家农业智能装备工程技术研究中心, 北京 100097)

摘要:为实现自动导航农机的避障,解决搭载在农机顶部的全景相机获取其周围360°的图像信息并精确实时快速检测出障碍物的问题,提出了一种改进YOLO v3 – tiny目标检测模型,实现了田间行人和其他农机的检测与识别。为了提高全景图像中小目标的检测效果,以检测速度快、轻量级的网络模型YOLO v3 – tiny为基础框架,通过融合浅层特征与第二YOLO预测层之前的拼接层作为第三预测层,增加小目标的检测效果;为了进一步增加网络模型对目标特征的提取能力,借鉴残差网络的思想,在YOLO v3 – tiny主干网络上引入残差模块,增加网络深度和学习能力,从而能够较好地提高网络的检测能力。为了验证模型的性能,建立了农田环境下1100幅行人与农机两类障碍物图像原始数据集,经数据扩增后得到2200幅图像数据集,按8:1:1将数据集划分为训练集、验证集和测试集,在Pytorch 1.8深度学习框架下进行模型训练,模型训练完后用220幅测试集图像对不同模型进行测试。试验结果表明,基于改进YOLO v3 – tiny的农田障碍物检测模型,平均准确率和召回率分别为95.5%和93.7%,相比于原网络模型,分别提高了5.6、5.2个百分点;单幅全景图像检测耗时为6.3 ms,视频流检测平均帧率为84.2 f/s,模型内存为64 MB。改进后的模型,在保证检测精度较高的同时,能够满足农机在运动状态下实时障碍物检测需求。

关键词:农田障碍物检测; 全景相机; YOLO v3 – tiny; 残差网络

中图分类号: TP242 文献标识码: A 文章编号: 1000-1298(2021)S0-0058-08

Farmland Obstacle Detection in Panoramic Image Based on Improved YOLO v3 – tiny

CHEN Bin¹ ZHANG Man¹ XU Hongzhen² LI Han² YIN Yanxin³

(1. Key Laboratory of Modern Precision Agriculture System Integration Research, Ministry of Education,
 China Agricultural University, Beijing 100083, China

2. Key Laboratory of Agricultural Information Acquisition Technology, Ministry of Agriculture and Rural Affairs,
 China Agricultural University, Beijing 100083, China

3. National Research Center of Intelligent Equipment for Agriculture, Beijing 100097, China

Abstract: In order to realize the obstacle avoidance of automatic navigation agricultural machinery and solve the problem that the panoramic camera mounted on the top of the agricultural machinery needs to accurately and quickly detect obstacles in real time to obtain the 360° image information around it, an improved YOLO v3 – tiny target detection model was proposed, which can realize the detection and identification of pedestrians and other agricultural machinery in the field. In order to improve the detection effect of small targets in panoramic images, the fast detection speed and lightweight network model YOLO v3 – tiny was used as the basic framework, and the splicing layer before the second YOLO prediction layer was used as the third prediction layer by fusing the shallow features with the second YOLO prediction layer to increase the detection effect of small targets; in order to further increase the network model's ability to extract target features, borrowing the idea of residual network, the residual module was introduced on the YOLO v3 – tiny backbone network to increase the depth and learning ability

收稿日期: 2021-07-03 修回日期: 2021-09-01

基金项目: 国家重点研发计划项目(2019YFB1312300 – 2019YFB1312305)和中国农业大学建设世界一流大学(学科)和特色发展引领专项资金项目(2021AC006)

作者简介: 陈斌(1996—),男,硕士生,主要从事机器视觉在农机自动导航中的应用研究,E-mail: SY20203081544@cau.edu.cn

通信作者: 张漫(1975—),女,教授,博士生导师,主要从事农业电气化与自动化研究,E-mail: cauzm@cau.edu.cn

of the network, so that it can better improve the detection capabilities of the network. In order to verify the performance of the model, totally 1 100 original data sets of pedestrian and agricultural machinery obstacles in the farmland environment were established, after data amplification, totally 2 200 images data sets were obtained, the data sets were divided into training set, verification and test set according to 8:1:1, and the model was trained under the Pytorch 1.8 deep learning framework. After the model was trained, totally 220 images of test set were used to test different models. The test results showed that the farmland obstacle detection model based on improved YOLO v3 - tiny had an average accuracy rate and recall rate of 95.5% and 93.7%, respectively, which were 5.6 percentage points and 5.2 percentage points higher than that of the original network model. Single panoramic image detection took 6.3 ms, the average frame rate of video stream detection was 84.2 f/s, and the model memory was 64 MB. The improved model can meet the real-time obstacle detection requirements of agricultural machinery in motion while ensuring high detection accuracy.

Key words: farmland obstacle detection; panoramic camera; YOLO v3 - tiny; residual network

0 引言

农业机械自动导航技术是实施精细农业的基础,可以有效减轻农机操作人员的劳动强度,提高作业精度与作业效率^[1-2]。然而,自主导航的农机在田间作业时,往往会遇到各种各样的运动障碍物,例如在田间行走的行人和协同作业的其他农机等,都会影响农机在农田作业时的安全性。因此,对农机周围障碍物进行精确并快速实时检测,以及后续农机在线路径规划与自主避障,提高农机自动导航的安全性具有重要的实际意义^[3-5]。

按照所使用的传感器种类可以将障碍物检测分为基于视觉^[6]、激光雷达^[7]、毫米波雷达^[8]和基于多传感器融合^[9]的方法。基于视觉的检测方法以价格低、便于安装、数据信息量丰富和检测算法较为成熟等特点,在农机自主导航障碍物检测和避障方面有着广泛的研究与应用。将机器视觉应用于农机的自动导航障碍物检测中,通过摄像头获取农机周围的环境图像信息,并根据图像中障碍物的特征对其进行分类与识别。农机自动导航中视觉设备往往是单目^[10]或双目相机^[11],其获取视野范围狭窄,无法全面检测农机周围的障碍物情况。全景相机作为一种新兴的获取全景图像的系统,其具有多个镜头,能够获取多个不同方向上的图像信息生成全景图像^[12-13]。将全景相机搭载至农机顶部,能够获取农机周围360°范围内的图像信息,实现农机360°范围内的障碍物检测,从而实现全景避障,极大提高了农机自动导航的安全性^[14-15]。

农田障碍物检测在机器视觉领域属于目标检测任务,在该领域内,基于卷积神经网络的目标检测算法因其高准确率与鲁棒性在近些年不断涌现并取得广泛应用^[16]。目前典型的深度学习目标检测算法中,一类是基于区域提取的目标检测算法,将检测过程分为定位与分类两个过程,代表算法有: R-

CNN^[17]、Fast R-CNN^[18]、Faster R-CNN^[19]等,另一类是基于端到端的目标检测算法,直接一步完成定位与分类,代表算法有 SSD^[20]、YOLO^[21]等。虽然基于区域提取的目标检测算法相较于基于端到端的目标检测算法在准确性上占有优势,但在生成物体的候选区域并对其进行提取的过程计算量大、检测速度慢,使得该类算法无法满足农机对周围障碍物实时检测的需求。而 YOLO 系列目标检测算法在保持较高准确率的同时,仍然有着高检测速度,特征提取过程也更着眼于整体,能够满足复杂农田环境下障碍物的精确快速检测^[22-24]。基于以上研究,将全景相机应用于复杂农田间障碍物检测时,XU 等^[15]基于光流传统方法的平均检测精度为 82.93%,检测单幅全景图像平均耗时为 0.801 s,对目标检测精度不高、检测过程处理耗时较长、实时性较差;而对于 YOLO v3 和 YOLO v4 等大型网络模型部署到全景相机检测目标则实时性较差、难以部署在移动端工作站。

综上所述,为实现农田环境下自主导航农机障碍物的实时、准确检测,本研究在农机顶部搭载全景相机获取农机周围的图像信息,以农田中的行人和相对于正在作业的其他农机两类目标作为运动障碍物,对原有 YOLO v3 - tiny 网络结构进行改进,并通过试验测试检测效果,以构建适合于复杂农田中行人与农机障碍物检测的模型。

1 材料与方法

1.1 试验材料

选用加拿大 PointGrey 公司生产的 Ladybug5 全景相机,如图 1 所示,安装在农机的顶部对自主导航农机周围环境进行图像采集,全景相机技术参数如表 1 所示。Ladybug5 全景相机具有 6 个广角镜头,其侧面 5 个镜头和顶部 1 个镜头,这些镜头获取不同方向的图像经处理可生成全景图像。考虑到农机

检测其自身周围障碍物的范围,将相机安装在农机顶部,搭载 Ladybug5 全景相机的试验平台为雷沃欧豹 M904-D 型拖拉机,试验场景如图 2 所示。本研究中没有使用顶部镜头获取的图像。当全景相机的分辨率设置为 2 048 像素 \times 2 448 像素时,能够提供 10 f/s 的高分辨率的图像数据,具有较好的实时性。



图 1 Ladybug5 全景相机

Fig. 1 Ladybug5 panoramic camera

表 1 Ladybug5 全景相机技术参数

Tab. 1 Technical parameters of panoramic camera

参数	数值/型式
型号	SonyICX655CCD
镜头数目/个	6
图像分辨率/(像素 \times 像素)	2 048 \times 2 448
A/D 转换位数/位	12
水平视场/(°)	360
球面覆盖率/%	90
采集频率/(f·s ⁻¹)	10
数据接口	USB 3.0

本试验在 2021 年 5—6 月开展,地点为河北省涿州市中国农业大学实验站。在安装 Windows 7 操作系统的计算机上,运行安装好的 LadybugCapPro 软件,全景相机通过 USB 3.0 数据传输线与计算机端相连接,并连接电源线接通电源为全景相机供电。当农机开始运行时,点击 LadybugCapPro 软件录制视频按钮采集视频流并保存,图 2b 为采集视频流中的一帧画面,采集的全景视频流(stream 文件)可保存至本地计算机。



图 2 试验现场

Fig. 2 Experiment field

1.2 基于全景相机的障碍物检测流程

基于搭载在自主作业农机顶部的全景相机对周围障碍物的检测流程如图 3 所示。预先完成数据集的采集和标注,通过改进 YOLO v3-tiny 网络模型对数据集完成训练,生成检测权重文件。在农机自主作业的同时,全景相机实时获取周围信息,将采集

的视频流解析成图像,通过 Ladybug5 全景相机配套软件 LadybugSDK 包和 OpenCV 库调用预生成的 weight 权重文件进行实时障碍物检测,最后呈现出障碍物检测结果。

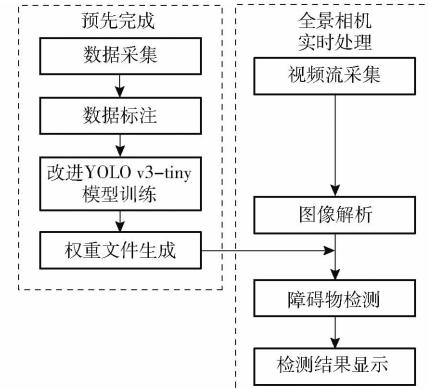


图 3 全景相机障碍物检测流程图

Fig. 3 Panoramic camera obstacle detection process

1.3 试验数据采集与数据集构建

对于自主作业农机,田间动态障碍物主要为行人和其他农机。因此,本研究主要针对行人和农机这两类障碍物进行检测识别。本试验中,农田障碍物数据集大多来源于试验农田全景相机拍摄并制作而成,对采集到的全景视频流文件,选取不同帧输出为 JPG 格式全景图像。如图 4 所示,为一帧通过视频流整理收集的 JPG 格式全景图像。为了丰富数据集的多样性和增加实际使用中模型的泛化能力,小部分数据集用手机拍摄、网上搜索等,共收集了 1 100 幅图像作为原始图像。



图 4 JPG 格式全景图像

Fig. 4 JPG format panoramic image

采用 LabelImg 标注工具对图像中的行人与农机进行手工数据标注矩形框,设定行人的标签为 person,农机的标签为 agricultural machinery,如图 5 所示。标注完成后,通过水平翻转和缩放等数据增广方式将图像数量由原始的 1 100 幅扩增到 2 200 幅。数据集按照 8:1:1 分为训练集、验证集、测试集,其中训练集图像为 1 760 幅,验证集和测试集分别为 220 幅。

1.4 评价指标

使用召回率(R)、调和均值($F1$)和平均精度均值(mAP)作为检测精度的评价指标,使用单幅全景图像检测帧耗时、视频流检测平均帧率、模型内存作



图 5 图像标注

Fig. 5 Image annotation

为检测速度的评价指标。

1.5 改进 YOLO v3-tiny 目标检测算法

1.5.1 YOLO v3-tiny 目标检测算法

YOLO v3-tiny 是一个轻量级的实时目标检测算法,由 YOLO v3 网络结构简化而来,在模型训练过程中能够减少内存占用,使得目标检测速度更快,更能满足复杂环境下实时检测需求,但也存在检测精度低和漏检率高等问题。YOLO v3-tiny 的网络结构包括 11 个 CBL 模块、6 个最大池化层 (Maxpool)、2 个卷积层、2 个路由层 (route)、1 个上采样层和 2 个 YOLO 预测层,一共 24 个网络层。CBL 模块由卷积层、归一化 BN 层和激活函数 Leaky 构成。非线性映射激活函数 Leaky ReLU 的引入,能提升整个网络的表达能力,并在一定程度上解决训练过程中梯度消失的问题。归一化 BN 层可以使激活函数的输入数据落在非饱和区域,缓解梯度消失问题,且抑制了参数微小变化随网络加深而被放大的问题,同时可以起到一定的正则效果,防止过拟合。最大池化层用于调整特征图尺寸,每经过步长为 2 的池化层后,特征图尺寸变为原来 $1/2$,经过步长为 1 的池化层,前后特征图尺寸不变。若输入网络图像尺寸被调整为 416 像素 \times 416 像素,经过一系列的 CBL 模块和最大池化操作,输出第 1 个 13×13 的 y_1 预测层,该输出层经历的网络层数较深,适

合对大目标检测。在第 1 层输出路径中引出第 8 个 CBL 模块通过路由层、CBL 模块和上采样操作与 y_1 输出路径中引出第 5 个 CBL 模块进行融合,卷积操作后输出第 2 个 26×26 的 y_2 预测层。YOLO v3-tiny 网络结构如图 6 所示。

由于田间作业时,全景相机安装在农机顶部,相机中心距离地面垂直高度大约 3 m,距离农机较近的行人在全景大像素图像中占的像素比例较小,距离农机稍远的行人在全景图像中占的像素更少,导致 YOLO v3-tiny 对距离全景相机较远的行人和农机等小目标漏检率较高。为了解决此问题,本研究通过融合浅层特征构建第三尺度预测层,并引入残差模块,实现对 YOLO v3-tiny 算法的改进。

1.5.2 融合浅层特征构建第三预测层

浅层网络提取的特征对小目标定位能力好,但是语义表征能力弱;深度网络提取的特征包含丰富的语义信息,但是容易丢失小目标的定位信息^[25]。当输入网络图像尺寸为 416 像素 \times 416 像素时,YOLO v3-tiny 有 13×13 和 26×26 两个目标检测尺度, 13×13 的检测层适合对大目标进行检测, 26×26 的检测层适合对中目标进行检测。将全景相机安装在农机的顶部采集 360° 全景信息,全景图像常用的分辨率是 2 048 像素 \times 2 448 像素,所以行人和农机等目标在全景图像中会显示的较小,而且目标距离农机越远,在全景图像上显示的就越小,当 YOLO v3-tiny 模型检测全景图像中这些小目标时,很容易出现漏检现象。针对模型存在的上述问题,克服 YOLO v3-tiny 浅层低维特征在网络深层丢失从而对小目标产生漏检,本研究通过融合浅层特征信息与第二检测尺度中的拼接层增加一个 52×52 的检测尺度层,作为第三预测层。第三预测层的特征信息来自浅层和第二层同维拼接后的特征图,包含了更多图像的低维特征信息,帮助模型提升对小

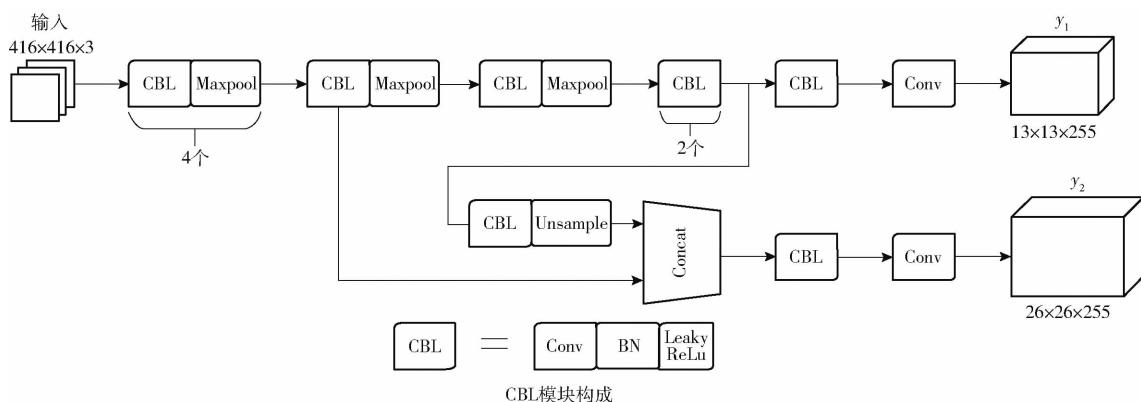


图 6 YOLO v3-tiny 网络结构图

Fig. 6 YOLO v3-tiny network structure diagram

目标的检测能力,从而最大程度减小目标的漏检情况。

1.5.3 残差模块引入

YOLO v3-tiny 的主干网络只有 8 个卷积层和 6 个池化层,很难对目标的特征有较好的提取效果。在卷积神经网络中,通过不断增加卷积网络的深度和宽度以寻求更优越的性能,然而随着网络的加深,网络却越发难以训练,一方面会产生梯度消失现象,网络深度增加到一定程度时容易出现梯度弥散和梯度爆炸的情况,阻碍浅层网络参数过程的收敛;另一方面越深的网络返回的梯度相关性越差,导致梯度更新也接近于随机扰动,当反向梯度消失后,整个网络的权重参数无法得到更新和优化,网络模型的性能会饱和。当网络层数达到一定数量以后,网络性能开始退化,但这种退化并不是由过拟合引起的,而是由网络层数变深引起的。最重要的是浅层网络提取的小目标特征信息将随着网络的加深而逐渐消失,造成小物体在较深的特征图上几乎不可见。模型的参数量也会随之增长,增加模型检测耗时,降低检测速度。

为了解决上述问题,本研究借鉴残差网络(ResNET)^[26]的思想,ResNET 的思想在于引入一个深度残差框架来解决梯度消失问题,即让卷积网络去学习残差映射,而不是期望每一个堆叠层的网络都完整地拟合潜在映射。残差网络由残差模块构成,每个残差模块包含两个分支:恒等映射和残差分支,如图 7 所示。假设在残差学习模块中,当输入为 x 时其基础映射记为 $H(x)$,希望其学习到的残差函数为 $F(x) = H(x) - x$,这样输出的学习特征为 $F(x) + x$ 。当残差为 0 时,此时构建模块只做了恒等映射,网络模型的检测精度至少不会损失。实际

上为 0 的残差函数不可能存在,这使得残差学习单元在恒等映射的基础上学习到新的特征信息,从而提高了网络学习效率。残差网络的公式为

$$y = F(x, \{W_i\}) + x \quad (1)$$

$$y = F(x, \{W_i\}) + W_s x \quad (2)$$

式中 y ——残差模块中的输出

$F(x, \{W_i\})$ ——后期训练残差映射函数

W_i, W_s ——输入参数

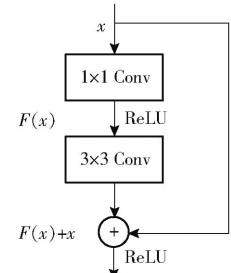


图 7 残差模块

Fig. 7 Residual module

加入残差模块使得小目标的特征不会随着网络的加深而导致梯度消失,且能更好地改善对小目标漏检率高的问题。在原有网络基础上选取 3×3 的卷积核对网络进行加深,通过引入 1×1 和 3×3 的卷积核组成一个残差模块, 1×1 的卷积对卷积核通道数不仅起到了降维的作用,在计算量大时将降低计算复杂度,而且给神经网络引入了更多的非线性变换,明显增加了残差块的深度,提高残差网络的表示能力。最终改进后的 YOLO v3-tiny 网络模型如图 8 所示。

2 试验结果与分析

模型训练试验平台为台式计算机,配置为 Intel(R) Xeon(R) CPU、32 GB 内存、GeForce GTX 1080Ti 型号 GPU、11 GB 显存,在 Ubuntu 18.04 操作

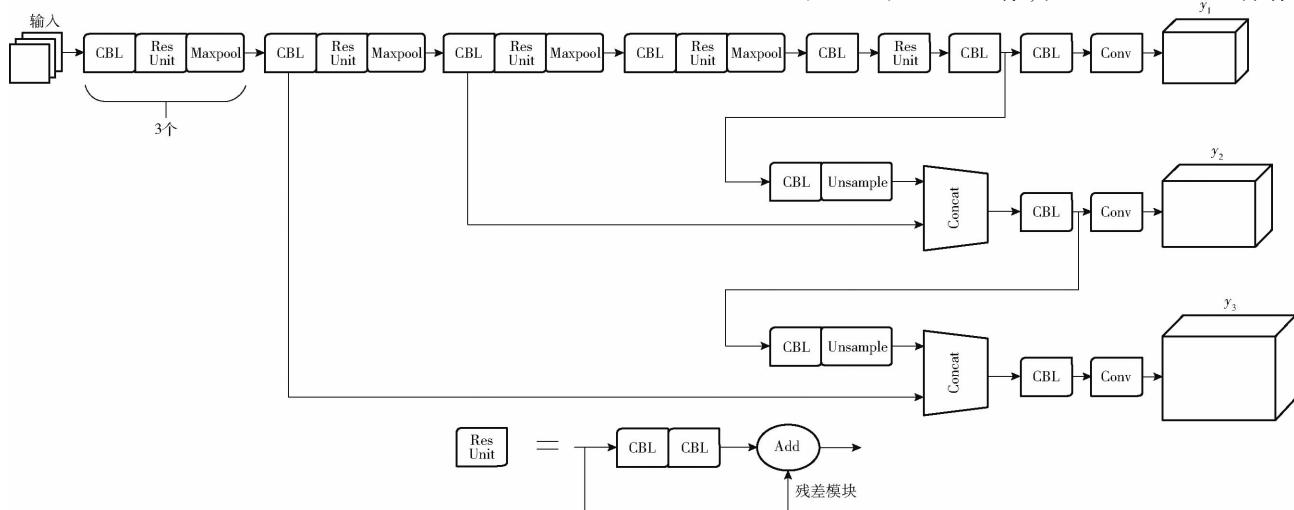


图 8 改进 YOLO v3-tiny 网络结构图

Fig. 8 Improved YOLO v3-tiny network architecture

系统下采用 python 3.8 编程语言, 搭建 Pytorch 1.8 深度学习框架, 安装有并行计算框架 CUDA 10.2 和 CUDNN 7.6 版本的深度学习神经网络加速库。在此基础上完成 YOLO v3-tiny 目标检测模型以及改进后模型的训练试验。

2.1 不同模型检测结果分析比较

为了提高全景图像中小目标检测精度, 减少漏检现象。将输入网络图像尺寸改为 608 像素 \times 608 像素, 训练参数为: 批尺寸(batch size)为 4, 初始学习率为 0.001, IoU 阈值(IoU thres)为 0.6。YOLO v2 已经采用 K-means 聚类得到先验框的尺寸^[27], YOLO v3 也沿用这种思想^[28]。先验框是针对不同尺度网络层确定的具有固定宽度和高度的初始候选框, 用来逻辑回归检测边界框。故先验框的选择对检测器的性能和最终检测结果都有影响。在模型训练开始前, 使用 K-means 算法聚类得到 9 个锚框(anchor)尺寸, 使模型更加贴合数据集中行人与农机的形态尺寸, 最终得到的 19 \times 19 尺度的先验框为(32, 38)、(62, 87)、(397, 413) 检测大目标, 38 \times 38 尺度的先验框为(9, 43)、(10, 16)、(13, 52) 检测中目标, 76 \times 76 尺度的先验框为(3, 17)、(5, 27)、(7, 38) 检测小目标。所有网络模型都从头开始训练, 训练轮次(epochs)为 100, 损失值下降至 1 左右结束训练。

训练完成后, 对数据集中的 220 幅测试集图像用于测试 YOLO v3-tiny、YOLO v3 和改进 YOLO v3-tiny 模型, 结果如表 2 所示。改进 YOLO v3-tiny 模型进行田间障碍物检测时在召回率方面比原 YOLO v3-tiny 提高了 5.2 个百分点, 平均精度均值提高了 5.6 个百分点, 调和均值 F1 提高了 4.6 个百分点, 改进后的模型 F1 更趋近于 100%。相比于 YOLO v3, 改进后的模型的召回率提高 2.6 个百分点, 平均精度均值高 1.5 个百分点, 调和均值 F1 高 2.1 个百分点, 改进后的模型内存约为 YOLO v3 的 1/4, 检测耗时比 YOLO v3 少 1/2, 视频流平均检测帧率达到 84.2 f/s, 比 YOLO v3 快 49.0%。虽然改进后的模型内存约为 YOLO v3-tiny 模型的 1.84

倍, 检测耗时是 YOLO v3-tiny 的 1.4 倍, 视频流平均检测速度比 YOLO v3-tiny 慢 21.4%, 但平均精度均值和召回率有较大的提升, 同时也能够满足农机在运动状态下障碍物实时检测需求, 更好地平衡了检测精度与检测速度。

表 2 不同模型检测结果比较

Tab. 2 Comparison of detection results of different models

模型	R/%	F1/%	mAP/%	单幅全景图像		模型内存/MB
				%	%	
YOLO v3-tiny	88.5	89.5	89.9	4.5	107.2	34.7
YOLO v3	91.1	92.0	94.0	12.6	56.5	246.3
本文模型	93.7	94.1	95.5	6.3	84.2	64.0

2.2 不同输入尺寸对模型性能影响分析

对不同输入尺寸进行了试验, 试验结果如表 3 所示。可以看出相较于 YOLO v3-tiny, 本研究提出的模型在 416 像素 \times 416 像素较小的输入尺寸下仍然能保持较高的检测能力, 且在 416 像素 \times 416 像素尺寸下较 YOLO v3-tiny 提升最大, 表明本文模型具有较强的鲁棒性。

2.3 不同模型检测效果对比

分别用表 2 中的 3 种模型对不同的原始全景图像进行检测, 检测结果如图 9 所示。对于图 9a 中左边图像, YOLO v3-tiny 对远处的农机产生了漏检, 而 YOLO v3 和本文模型都完全地检测出障碍物; 对于图 9a 中间图像, YOLO v3-tiny 漏检了一个行人, YOLO v3 和本文模型也都完全检测出障碍物; 对于图 9a 最右边图像, YOLO v3-tiny 漏检了从右边数第 3 个行人, YOLO v3 漏检了一个从右边数第 2 个行人, 而本文模型则完全检测出障碍物, 没有出现漏检行人与农机的现象。说明本文模型具有较好的检测能力和效果。

3 结论

(1) 为解决复杂农田障碍物检测时对小目标检

表 3 不同输入尺寸下的模型检测结果比较

Tab. 3 Comparison of detection results under different input sizes

输入尺寸/ (像素 \times 像素)	模型	R/%	F1/%	mAP/%	单幅全景图像		模型内存/MB
					检测耗时/ms	帧率/(f·s ⁻¹)	
512 \times 512	YOLO v3-tiny	68.6	76.0	75.2	4.2	105.2	34.7
	YOLO v3	90.4	92.2	93.3	12.6	56.9	246.3
	本文模型	91.5	92.5	94.0	6.2	86.8	64.0
416 \times 416	YOLO v3-tiny	61.9	66.8	68.2	4.1	108.6	34.7
	YOLO v3	89.5	84.9	90.7	12.8	57.0	246.3
	本文模型	89.9	88.5	93.1	6.3	87.5	64.0

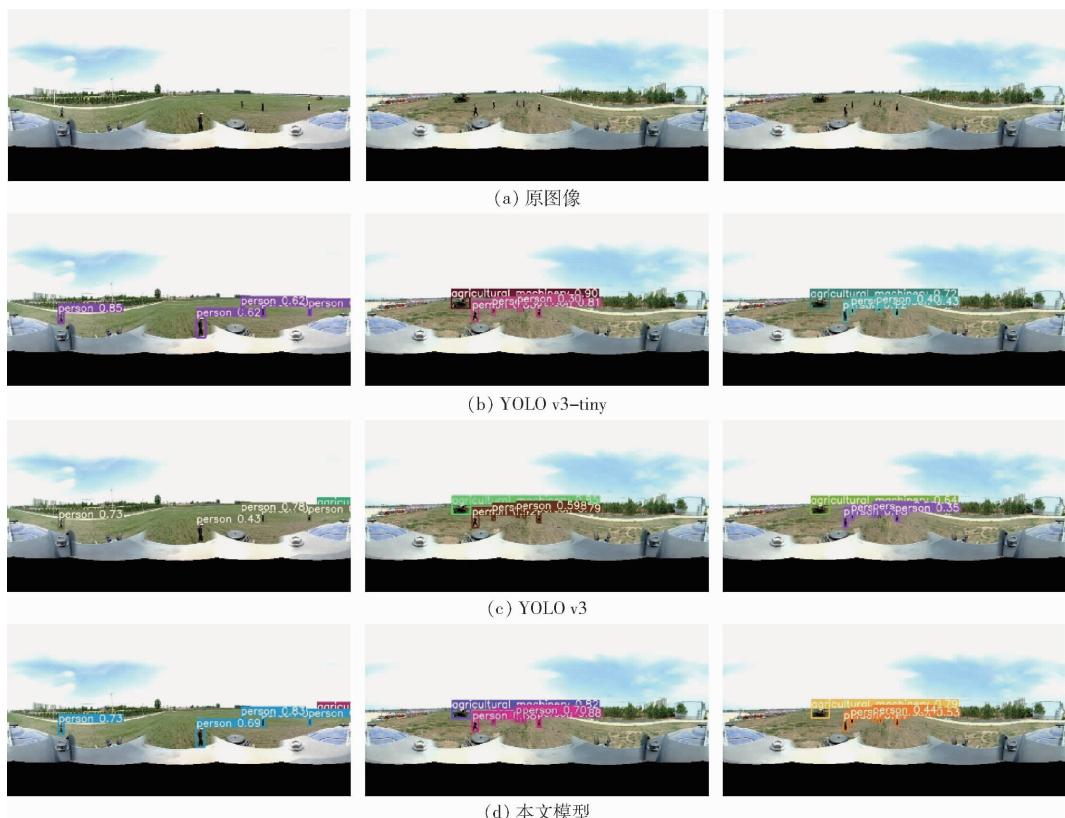


图 9 不同模型检测结果

Fig. 9 Test results of different models

测精度不高、检测过程处理耗时较长、实时性较差等问题,搭建了基于全景相机的检测试验平台,并提出了基于改进 YOLO v3-tiny 的目标检测模型。

(2) 针对农田中的主要运动障碍物,制作了行人与其他农机这两类障碍物数据集,并分别用于

YOLO v3-tiny、YOLO v3 和改进 YOLO v3-tiny 模型。试验结果表明,本文模型具有更高的检测精度和较低的检测耗时;本文模型在不同输入尺寸下仍然能够保持较高的检测精度,表明本文模型具有较高的鲁棒性。

参 考 文 献

- [1] 张漫,季宇寒,李世超,等.农业机械导航技术研究进展[J].农业机械学报,2020,51(4):1-18.
ZHANG Man, JI Yuhuan, LI Shichao, et al. Research progress of agricultural machinery navigation technology[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(4):1-18. (in Chinese)
- [2] 胡静涛,高雷,白晓平,等.农业机械自动导航技术研究进展[J].农业工程学报,2015,31(10):1-10.
HU Jingtao, GAO Lei, BAI Xiaoping, et al. Review of research on automatic guidance of agricultural vehicles[J]. Transactions of the CSAE, 2015, 31(10):1-10. (in Chinese)
- [3] 刘宇峰,姬长英,田光兆,等.自主导航农业机械避障路径规划[J].华南农业大学学报,2020,41(2):117-125.
LIU Yufeng, JI Changying, TIAN Guangzhao, et al. Obstacle avoidance path planning for autonomous navigation agricultural machinery[J]. Journal of South China Agricultural University, 2020, 41(2):117-125. (in Chinese)
- [4] 郭成洋,刘美辰,高泽宁,等.基于改进人工势场法的农机避障方法研究[J].中国农机化学报,2020,41(3):152-157.
GUO Chengyang, LIU Meichen, GAO Zening, et al. Research on agricultural machinery obstacle avoidance method based on improved artificial potential field method[J]. Journal of Chinese Agricultural Mechanization, 2020, 41(3):152-157. (in Chinese)
- [5] 刘美辰.农机作业障碍物检测与避障方法研究[D].杨凌:西北农林科技大学,2018.
LIU Meichen. Research on inspection and obstacle avoidance methods of agro-machinery obstructions[D]. Yangling: Northwest A&F University, 2018. (in Chinese)
- [6] 宋怀波,何东健,辛湘俊.基于机器视觉的非结构化道路检测与障碍物识别方法[J].农业工程学报,2011,27(6):225-230.
SONG Huaibo, HE Dongjian, XIN Xiangjun. Unstructured road detection and obstacle recognition algorithm based on machine vision[J]. Transactions of the CSAE, 2011, 27(6):225-230. (in Chinese)
- [7] 黄如林,梁华为,陈佳佳,等.基于激光雷达的无人驾驶汽车动态障碍物检测、跟踪与识别方法[J].机器人,2016,38(4):437-443.
HUANG Rulin, LIANG Huawei, CHEN Jiajia, et al. LiDAR based dynamic obstacle detection, tracking and recognition method

- for driverless cars [J]. Robot, 2016, 38(4):437–443. (in Chinese)
- [8] 孙柯, 吴开华, 王亚涛, 等. 基于毫米波雷达的植保无人机避障系统研究 [J]. 传感器与微系统, 2020, 39(6):73–76.
SUN Ke, WU Kaihua, WANG Yatao, et al. Research on obstacle avoidance system of plant protection UAV based on millimeter wave radar [J]. Transducer and Microsystem Technologies, 2020, 39(6):73–76. (in Chinese)
- [9] 翟光耀, 陈蓉, 张剑锋, 等. 基于毫米波雷达和机器视觉信息融合的障碍物检测 [J]. 物联网学报, 2017, 1(2):76–83.
Zhai Guangyao, CHEN Rong, ZHANG Jianfeng, et al. Tramway obstacles detection based on information fusion of MMV radar and machine vision [J]. Chinese Journal on Internet of Things, 2017, 1(2):76–83. (in Chinese)
- [10] 王泽民, 高俊钗. 单目视觉障碍物测距精度分析 [J]. 电子测试, 2016(18):36–37.
WANG Zemin, GAO Junchai. Accuracy analysis of monocular vision obstacle ranging [J]. Electronic Test, 2016(18):36–37. (in Chinese)
- [11] 黄玉强, 叶磊. 基于双目视觉的目标测距 [J]. 汽车实用技术, 2017(1):148–151.
HUANG Yuqiang, YE Lei. Range-measuring of target based on binocular stereo vision [J]. Automobile Applied Technology, 2017(1):148–151. (in Chinese)
- [12] 王健, 张振海, 李科杰, 等. 全景视觉系统发展与应用 [J]. 计算机测量与控制, 2014, 22(6):1664–1666, 1679.
WANG Jian, ZHANG Zhenhai, LI Kejie, et al. Development and application of panoramic vision system [J]. Computer Measurement and Control, 2014, 22(6):1664–1666, 1679. (in Chinese)
- [13] 曹文君, 赵祚喜. Ladybug 系列多目全景视觉技术的应用研究 [J]. 机械与电子, 2017, 35(12):27–30.
CAO Wenjun, ZHAO Zuoxi. Study on application of multi-view panoramic vision technology to Ladybug series [J]. Machinery and Electronics, 2017, 35(12):27–30. (in Chinese)
- [14] YANG L, NOGUCHI N. Human detection for a robot tractor using omni-directional stereo vision [J]. Computers & Electronics in Agriculture, 2012, 89(3):116–125.
- [15] XU Hongzhen, LI Shichao, JI Yuhua, et al. Dynamic obstacle detection based on panoramic vision in the moving state of agricultural machineries [J]. Computers and Electronics in Agriculture, 2021, 184(5):1–16.
- [16] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述 [J]. 计算机学报, 2017, 40(6):1229–1251.
ZHOU Feiyan, JIN Linpeng, DONG Jun. Review of convolutional neural network [J]. Chinese Journal of Computers, 2017, 40(6):1229–1251. (in Chinese)
- [17] GIRSHICK R, DONAHUE J, DARRELL T, et al. Region-based convolutional networks for accurate object detection and segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(1):142–158.
- [18] GIRSHICK R. Fast R-CNN [C] // 2015 IEEE International Conference on Computer Vision (ICCV), 2015:1440–1448.
- [19] REN Shaoqing, HE Kaiming, 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.
- [20] LIU W, ANGUELOY D, ERHAN D, et al. SSD: single shot multibox detector [C] // European Conference on Computer Vision. Springer, Cham, 2016:21–37.
- [21] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016:779–788.
- [22] 李文涛, 张岩, 莫锦秋, 等. 基于改进 YOLOv3-tiny 的田间行人与农机障碍物检测 [J]. 农业机械学报, 2020, 51(增刊1):1–8, 33.
LI Wentao, ZHANG Yan, MO Jinqiu, et al. Detection of pedestrians and agricultural machinery obstacles in field based on improved YOLOv3-tiny [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(Supp. 1):1–8, 33. (in Chinese)
- [23] 蔡成涛, 吴科君, 刘秋飞, 等. 基于改进 YOLO 算法的全景多目标实时检测 [J]. 计算机工程与设计, 2018, 39(10):267–272, 279.
CAI Chengtao, WU Kejun, LIU Qiufei, et al. Real-time panoramic multi-target detection based on improved YOLO algorithm [J]. Computer Engineering and Design, 2018, 39(10):267–272, 279. (in Chinese)
- [24] 蔡舒平, 孙仲鸣, 刘慧, 等. 基于改进型 YOLOv4 的果园障碍物实时检测方法 [J]. 农业工程学报, 2021, 37(2):36–43.
CAI Shuping, SUN Zhongming, LIU Hui, et al. Real-time detection method of obstacles in orchard based on improved YOLOv4 [J]. Transactions of the CSAE, 2021, 37(2):36–43. (in Chinese)
- [25] 王丹峰, 陈超波, 马天力, 等. 基于深度可分离卷积的 YOLOv3 行人检测算法 [J]. 计算机应用与软件, 2020, 37(6):218–223.
WANG Danfeng, CHEN Chaobo, MA Tianli, et al. YOLOv3 pedestrian detection algorithm based on deep separable convolution [J]. Computer Applications and Software, 2020, 37(6):218–223. (in Chinese)
- [26] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016:770–778.
- [27] REDMON J, FARHADI A. YOLO9000: better, faster, stronger [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017:6517–6525.
- [28] REDMON J, FARHADI A. YOLOv3: an incremental improvement [J]. arXiv: 1804.02767v1, 2018.