

# 基于改进YOLOX的群养生猪轻量化目标检测方法

邓铭辉 龚俊杰 郑飘逸 马闯 尹艳玲

(东北农业大学电气与信息学院, 哈尔滨 150030)

**摘要:** 针对目前群养生猪智能化养殖中复杂环境下猪只目标检测精度低的问题,提出了一种基于改进YOLOX的群养生猪轻量化目标检测模型Ghost-YOLOX-BiFPN。该模型采用Ghost卷积替换普通卷积,在减少主干网络参数的情况下,提高了模型的特征提取能力。使用加入CBAM注意力机制的BiFPN作为模型的Neck部分,使得模型充分融合不同体型猪只的特征图,并使用Focal Loss损失函数解决猪圈环境下猪只与背景难以区分的问题,增强模型对正样本的学习。实验结果表明,改进后模型对群养生猪检测精度为95.80%,相比于原始YOLOX算法,检测精度提升2.84个百分点,参数量降低63%。最后将本文轻量化模型部署到Nvidia Jetson Nano移动端开发板,通过在开发板上实际运行表明,本文所提模型实现了对不同大小、不同品种猪只的准确识别,为后续智能化生猪养殖提供支持。

**关键词:** 猪只目标检测;YOLOX;图像处理;移动端部署

中图分类号:TP391 文献标识码:A 文章编号:1000-1298(2023)11-0277-09

OSID:



## Lightweight Target Detection Method for Group-raised Pigs Based on Improved YOLOX

DENG Minghui GONG Junjie ZHENG Piaoyi MA Chuang YIN Yanling

(College of Electrical Engineering and Information, Northeast Agricultural University, Harbin 150030, China)

**Abstract:** Aiming at the problem of low pig target detection accuracy in the complex environment in the current intelligent breeding of group-raised pigs, a lightweight target detection model for group-raised pigs based on improved YOLOX, Ghost-YOLOX-BiFPN was proposed. The Ghost convolution was used to replace the traditional convolution, which greatly reduced the number of model parameters. BiFPN was used as the model feature fusion network to effectively fuse the feature maps of pigs of different sizes, and Focal Loss function was added in the post-processing stage, increasing the learning of the model to the positive sample target, and reducing the rate of missed detection. The results showed that the improved model had a detection accuracy of 95.80% for pigs, and the number of model parameters were  $2.001 \times 10^7$ . Compared with the original YOLOX algorithm, the detection accuracy and recall were increased by 2.84 percentage points and 3.22 percentage points, respectively, and the number of model parameters were reduced by 63%. Finally, the proposed algorithm model was deployed to the Nvidia Jetson Nano mobile terminal development board. The actual operation on the development board showed that the model proposed can guarantee the recognition rate of pigs and realize the accurate recognition of pigs of different sizes and breeds. The research result can provide support for the subsequent establishment of intelligent pig breeding system.

**Key words:** pig target detection; YOLOX; image processing; mobile deployment

## 0 引言

猪只目标检测是建立智能化生猪养殖系统的基

础,对后续的个体轨迹追踪和病态检测等具有重要意义<sup>[1]</sup>。当前,市面上有着大量的生猪养殖系统,现有系统能够在简单猪只饲养环境下实现较好的识

收稿日期:2023-05-08 修回日期:2023-06-19

基金项目:国家自然科学基金面上项目(32172784)

作者简介:邓铭辉(1976—),男,副教授,博士,主要从事农业人工智能研究,E-mail:markdmh@163.com

别,难以做到在猪只体尺差异较大、背景复杂、多品种等复杂猪只饲养环境下的准确识别。

猪只目标检测目前主要是使用机器视觉技术完成,避免了传统方法导致的动物应激<sup>[2-5]</sup>。机器视觉技术具有无接触、成本低等优点,在猪只养殖过程中得到大量应用<sup>[6]</sup>。目前生猪个体检测研究已取得了一定进展。杨心等<sup>[7]</sup>通过基于距离变换的粘连猪体分割和广义 Hough 聚类的方法对生猪头、尾进行检测,检测平均正确率达到 87.28%。段玉瑶等<sup>[8]</sup>结合生猪养殖环境提出了一种优化特征提取的压缩感知跟踪算法,将跟踪窗口设置为类似于猪只体型的椭圆形,并结合灰度和纹理特征来进行生猪目标跟踪。马丽等<sup>[9]</sup>经过图像处理获取猪只轮廓图,提出联立猪只外接矩形高宽比和低频傅里叶系数构建猪只侧视图的特征向量,利用马氏距离判别法进行检测,检测准确率达到 91.70%。谢双云<sup>[10]</sup>采用高斯混合建模(GMM)和图像粒化方法,依据图像序列的前景图分析粒子运动属性,融合前景图和粒化图,使用一种混合高斯背景建模和图像粒化相结合的方法对群养生猪进行目标检测。朱家骥等<sup>[11]</sup>采用背景减除法与帧间差分法加权平均的目标检测方法对单只猪进行目标检测。

以上基于机器视觉的生猪目标检测方法存在精确度较低、模型容量大、检测时间长等问题,相比于传统机器学习方法,深度学习在目标检测领域有着巨大的优势,由于卷积神经网络可以实现对目标高维特征的深度提取,使得在猪圈背景下生猪个体目标的精确检测成为可能。宁远霖等<sup>[12]</sup>提出在 YOLO v5 骨干网络集成融合通道和空间注意力的模块和 Transformer 自注意力模块,提高了群养生猪的目标检测和计数的准确率。燕红文等<sup>[13]</sup>在 Tiny-YOLO 模型中引入特征金字塔注意力信息,对 Tiny-YOLO 模型进行了改进,从而有效地对群养生猪进行多目标检测。沈明霞等<sup>[14]</sup>针对仔猪个体较小、易粘连和杂物遮挡等现象,提出基于 YOLO v3 的初生仔猪目标识别方法。上述目标检测模型仅针对一般环境下群养生猪检测,检测精度和检测速度达到一定的平衡,但是实际上猪圈环境复杂,常出现不同品种、不同体型混养等情况。针对这种情况,特征金字塔能够兼顾各感受野信息,在像素级别获取不同尺度特征,已经成熟应用在图像领域<sup>[15-17]</sup>,YOLOX 中使用的路径聚合网络(Path aggregation network, PANet)金字塔结构仅以基本的线性叠加实现特征融合,本文引入能够深度融合特征图的双向加权特征金字塔网络(Bi-directional feature pyramid network, BiFPN)作为网络的特征融合部分,在原始

YOLOX 网络<sup>[18]</sup>基础上进行改进,结合 Ghost 卷积和特征金字塔网络,提出一种能够在边缘设备上实时检测的同时,对不同大小、相互遮挡、粘连等复杂环境下的猪只具有较高检测精度的群养生猪目标检测方法。

## 1 数据采集与预处理

### 1.1 数据采集

实验数据采集自黑龙江省哈尔滨市阿城生猪养殖场。考虑到实际饲养中常出现不同品种、不同大小猪只混养情况,实验选取 45 头长白猪(25 头成年猪,20 头幼年猪)、25 头北京黑猪(9 头成年猪,16 头幼年猪)、16 头黄毛猪(4 头成年猪,12 头幼年猪),共 86 头,分别放入正常养殖区域和母猪、仔猪养殖区域,使用海康威视 DS-E11 型摄像头进行拍摄,采集到的图像分辨率为 1 920 像素 × 1 080 像素,俯视高度约为 2.5 m。

### 1.2 数据预处理

选取原始图像 3 278 幅,其中正常养殖区域 2 200 幅,母猪、仔猪养殖区域 1 078 幅。为防止因数据集不足而产生模型过拟合,本研究对部分原始数据采取随机增加高斯噪声、改变对比度、调整锐度、改变亮度等变换方式进行图像增强。具体变换策略为随机调整对比度、增加高斯噪声方差 0.01、锐度降低 0~20%、旋转(90°、180°、270°)、亮度上调 50% 和 35% 两种梯度,增强示例如图 1 所示。



图 1 图像增强示例

Fig. 1 Image enhancement examples

### 1.3 数据集标注

经过预处理的数据集还需人工进行标注,本文使用 Labellmg 软件对视频中分割的单帧图像进行标注。在真实的群养生猪环境中,会出现栏杆遮挡生猪目标和光照变化等情况,基于这些异常情况数据的标注策略为:当猪只被栏杆遮挡时,保留入镜部分,栏杆两侧均可见时则全部保留;当生猪粘连时标记所有可见猪只。部分标注数据集如

图 2 所示。



图 2 标注数据集

Fig. 2 Annotation dataset

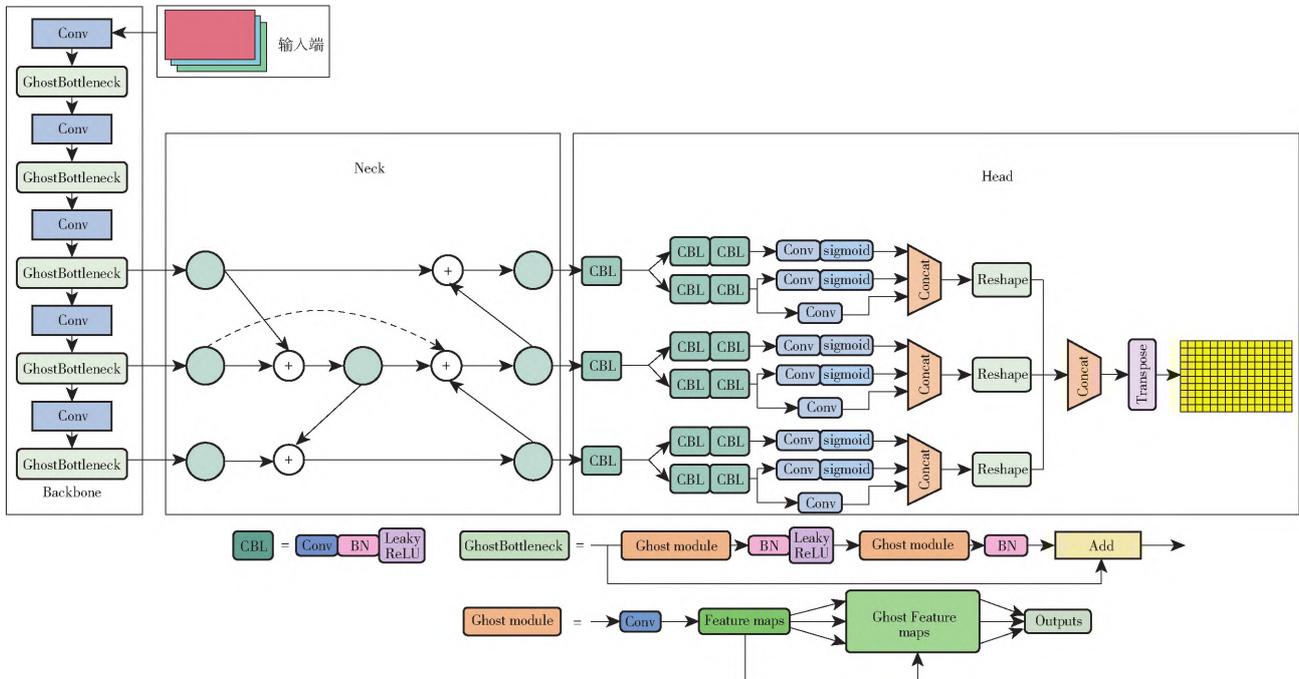


图 3 Ghost-YOLOX-BiFPN 模型结构图

Fig. 3 Ghost-YOLOX-BiFPN model structure diagram

YOLOX 模型的 Backbone 为 CSPDarknet53, CSPDarknet53 具有大量参数, 不便于部署到内存和算力资源很有限的边缘设备上。针对复杂的群养生猪环境和边缘设备部署要求, 选择使用提取特征更细粒度、更轻量化的 Ghost 模块重新构建骨干网络模型。与此同时, 原 YOLOX 模型中的路径聚合网络 (PANet<sup>[19]</sup>) 虽然能将不同特征层进行有效融合, 但本质上仍是将不同特征进行简单相加, 使用 PANet 训练将会影响模型最终的效果。为此本文引入添加 CBAM<sup>[20]</sup> 注意力机制的加权双向特征金字塔网络 (BiFPN<sup>[21]</sup>) 作为模型的特征融合模块。本文在检测头模块则保留 YOLOX 所提出的解耦头结构。该结构考虑到分类的定位所关注的内容不同, 采用不同分支处理不同层次的特征图, 从而大幅提升了收敛速度, 同时 YOLOX 的检测头是无锚框的, 因此相较于 YOLO v5 参数减少 2/3, 为模型带来了更快的收敛速度和检测速度。

由网络将输入图像宽高修改为尺寸为 460 像素 × 460 像素的 RGB 图像, 首先通过由 GhostBottleneck 组成的骨干网络生成 20 × 20、40 × 40、80 × 80 共 3 种多尺度特征图, 接着将主干网络

## 2 YOLOX 改进算法

### 2.1 Ghost-YOLOX-BiFPN 模型

YOLOX 算法由旷视科技基于 YOLO v5 算法提出, 相较于 YOLO v5, YOLOX 在 Head 部分使用解耦头替换了原来耦合的检测头。本文在 YOLOX 基础上提出了图 3 所示的 Ghost-YOLOX-BiFPN 模型。

输出的特征图输入 BiFPN 进行多层次细节信息提取和特征融合, 然后将融合后含有语义信息的特征图送入解耦的检测头模块进行后处理, 得到 Ghost-YOLOX-BiFPN 模型。

### 2.2 融合 Ghost 的 YOLOX 算法

Ghost 模块能够对传统卷积神经网络模型 (CNN) 特征图的冗余进行有效处理。模块首先使用 1 × 1 卷积对输入的特征图降维生成原始特征图, 然后对原始特征图逐一进行线性变换从而获得一部分冗余的特征图, 最后将前后获得的特征图在通道维度上进行堆叠。Ghost 模块如图 4 所示。

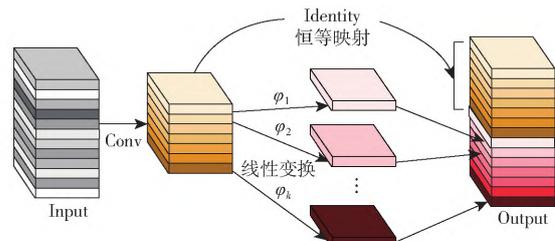


图 4 Ghost 模块

Fig. 4 Ghost module

GhostBottleneck 主要由 Ghost 模块堆砌而成, 如图 5 所示, 其中第 1 个 Ghost 模块作为扩展层增加

通道数量。第2个 Ghost 模块通过减少通道数量来匹配网络中的 shortcuts。根据步长的不同, GhostBottleneck 的实现方式也不同,步长为 1 时, GhostBottleneck 中由 2 个不同作用的 Ghost 模块串联而成,当步长为 2 时,在 2 个串联的 Ghost 模块中间加入深度可分离卷积,从而配合上下两层 Ghost 模块进行宽高压缩。

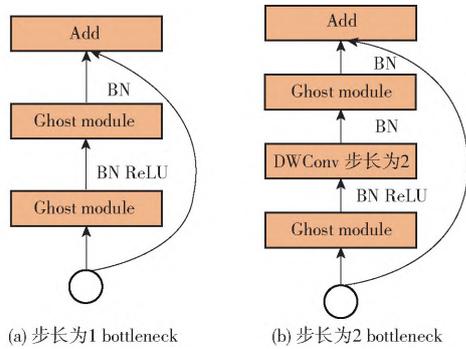


图 5 GhostBottleneck 结构  
Fig. 5 GhostBottleneck structure

### 2.3 加权双向特征金字塔网络

由于群养生猪目标大小不一,因此会有不同分辨率尺寸的特征在训练中产生,如果这些特征依旧被 PANet 以简单线性叠加方式相加,将会导致不同体型猪只的特征对融合后输出的特征产生不平等的权重,从而造成大尺寸的特征被更多的融入网络中,而小尺寸特征却得不到重视。与只有一条自顶向下和一条自底向上路径的 PANet 不同, BiFPN 将每个双向路径视为一个特征网络层,多次重复同一层以启用更高级的特征融合,能够针对融合的不同尺寸特征增加权重,动态可学习的调整每个尺寸的贡献度,同时其中的残差机制使得特征的表达能力增强。更适用于复杂的群养生猪环境,结构对比如图 6 所示。

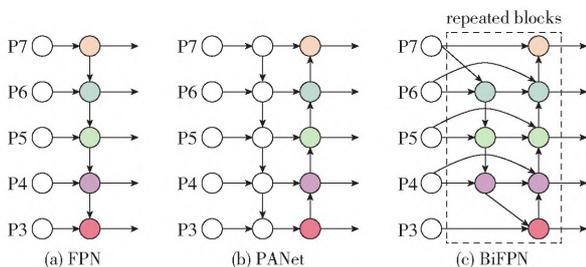


图 6 FPN、PANet、BiFPN 结构对比  
Fig. 6 Comparison of FPN, PANet and BiFPN structures

### 2.4 CBAM 注意力机制模块

为了提高网络对于猪体特征的识别,注意力机制能够通过抑制次要信息,关注与目标相关的区域信息以提高识别精度,可用于低阶特征图的非线性信息融合<sup>[22-25]</sup>。本文将结合了通道和空间注意力机制的 CBAM 模块加入到 BiFPN 中,从而帮助

BiFPN 提取特征图的有效部分。

CBAM 注意力模块分为空间注意力和通道注意力两部分,基本结构如图 7 所示。图 7 中绿色长方体部分为通道注意力,紫色长方体部分为空间注意力。特征图输入后,先进入通道注意力,基于特征图的宽、高进行池化操作,接着经过共享多层感知机得到通道权重,归一化注意力权重,最后通过乘法逐通道加权到原始输入特征图。计算公式为

$$M_c(F) = \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{Maxpool}(F))) = \sigma(W_1(W_0(F_{\text{avg}}^c)) + W_1(W_0(F_{\text{max}}^c))) \quad (1)$$

式中  $M_c$ ——通道注意力特征

$F$ ——输入特征图

$\sigma$ ——sigmoid 函数

MLP——多层感知机

AvgPool——平均池化

MaxPool——最大池化

$W_1$ ——多层感知机权重 1

$W_0$ ——多层感知机权重 0

$F_{\text{avg}}^c$ ——平均池化特征

$F_{\text{max}}^c$ ——最大池化特征

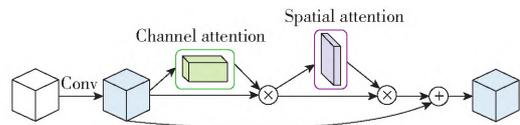


图 7 CBAM 注意力模块结构

Fig. 7 Structure diagram of CBAM attention module

经通道注意力输出的特征图同样基于特征图的宽度和高度同时进行最大池化和平均池化,将获得的两个维度相同的特征图拼接在一起,然后经过  $7 \times 7$  卷积得到空间注意力矩阵,最后将此矩阵与原特征图进行相乘,从而获取空间注意力特征图。计算公式为

$$M_s(F) = \sigma(f_{7 \times 7}([\text{AvgPool}(F); \text{MaxPool}(F)])) = \sigma(f_{7 \times 7}([F_{\text{avg}}^s; F_{\text{max}}^s])) \quad (2)$$

式中  $f_{7 \times 7}$ ——大小为  $7 \times 7$  的卷积核

$M_s$ ——空间注意力特征

在空间注意力模块中,全局平均池化和最大池化获得了空间注意力特征,通过卷积建立了空间特征间的相关性,同时保持了输入输出维度的不变。通过卷积核为  $7 \times 7$  的卷积操作,极大地减少参数和计算量,有利于建立高维度的空间特征相关性。

### 2.5 损失函数

生猪养殖环境下常有背景与目标相似度较高的

情况出现,正负样本之间难以区分。在训练中,由于存在着大量背景负样本,会造成模型对前景正样本目标的学习不充分,尽管 mAP 很高,但是召回率较低。为提高模型对于正样本的学习能力,本文引入 Focal Loss<sup>[26]</sup> 损失函数替换掉原模型的交叉熵损失函数。

### 2.6 评价指标

结合本次实验的实际情况,选择使用精确率  $P$ 、召回率  $R$ 、平均精度均值 (mAP) 和检测速度 (FPS) 作为评价标准。

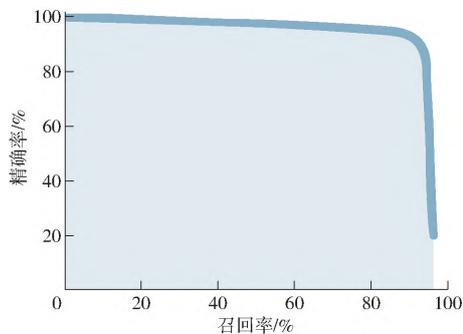
## 3 实验与结果分析

对养殖场 86 头群养生猪进行拍摄共获取图像 3 278 幅,经图像增强后共获得猪只数据集 4 557 幅,其中 3 645 幅为训练集,验证集与测试集分别为 456 幅,以此为基础构建群养生猪数据集。经统计,训练集、验证集和测试集分别含有标注框 40 126、5 142、5 011 个。统计结果如表 1 所示。

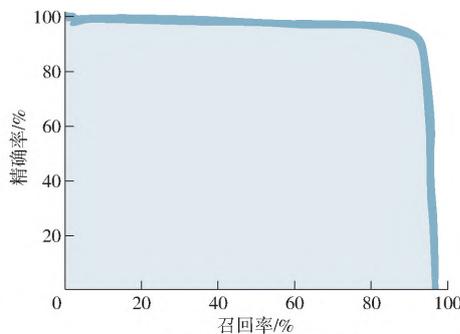
表 1 数据集划分及边框数量

Tab.1 Dataset partitioning and number of borders

参数	数据集			总计
	训练集	验证集	测试集	
图像数量/幅	3 645	456	456	4 557
标注框数量/个	40 126	5 142	5 011	50 279



(a) YOLOX-S



(b) Ghost-YOLOX-BiFPN

图 8 YOLOX-S 和 Ghost-YOLOX-BiFPN 训练  $P-R$  曲线对比

Fig.8 Comparisons of  $P-R$  curves for YOLOX-S and Ghost-YOLOX-BiFPN training

表 2 消融实验结果

Tab.2 Ablation experiment

实验序号	Ghost	BiFPN	CBAM	Focal Loss	参数量	召回率/%	mAP/%	FPS/( $f \cdot s^{-1}$ )
1					$5.420 \times 10^7$	90.96	92.96	60.66
2	√				$3.580 \times 10^7$	92.06	93.76	49.00
3		√	√		$3.990 \times 10^7$	92.62	94.43	41.49
4	√			√	$3.580 \times 10^7$	91.89	94.56	47.52
5	√	√	√	√	$2.001 \times 10^7$	94.18	95.80	40.13

注:√表示使用该种改进策略。

积,显著地降低了参数量,表明 Ghost 卷积操作相比传统卷积方式并未大量减少有效特征,在保证精度

实验基准模型为 YOLOX-S,并使用相同数据集进行消融实验和对比实验以验证改进策略的有效性,从而确定模型有效性。模型在 NVIDIA GTX 1080TI GPU 上进行训练。

### 3.1 模型训练

所有模型使用 voc 数据集权重作为初始权重,训练世代设置为 200 轮,其中前 50 轮为冻结训练,不改变网络主干参数,仅对网络后端进行微调,后 150 轮为解冻训练,对网络的所有参数进行调整。训练数据采用 mosaic、mixup 两种增强方式,优化器采用随机梯度调整法,初始学习率设置为 0.01,动量为 0.937,使用余弦退火算法动态优化学习率。其中 YOLOX-S 模型和 Ghost-YOLOX-BiFPN 模型训练过程  $P-R$  曲线对比如图 8 所示。由图 8 可得,本文提出的 Ghost-YOLOX-BiFPN 模型相较于 YOLOX-S 的精度和召回率更高,证明本文改进策略有效。

### 3.2 消融实验

使用群养生猪数据集对各改进策略进行训练和评估,各改进策略对基准模型 (YOLOX-S) 的参数量、召回率、平均精度均值、检测速度的影响如表 2 所示。

表 2 中实验 2~5 为各改进策略对基准模型 (实验 1) 的影响。实验 2 中使用 Ghost 卷积替换传统卷

的同时带来参数量的减少。实验 3 通过将基准模型中特征融合网络由 PANet 替换为添加了 CBAM 注

注意力机制的 BiFPN, mAP 增加 1.47 个百分点, FPS 降低 19.17 f/s, 检测速度相较于原模型略有降低, 但其检测精度的提升获得的收益较大。通过训练以动态可学习方式调整目标的权重系数, 使得模型比 PANet 结构有更多的特征, 同时也证明了抛弃传统的随机加权方式, 使用加入 CBAM 注意力机制的加权双向特征金字塔作为特征融合网络能够使模型的识别能力提高。实验 4 在实验 2 的基础上使用 Focal Loss 损失函数替换原本目标损失中的交叉熵损失, 在不增加模型参数的情况下将 mAP 提高了 0.80 个百分点, 证明了 Focal Loss 损失函数对于平衡不同大小目标的损失有一定作用。实验 5 为本文提出的改进模型, 使用添加 CBAM 的 BiFPN 替换了 PANet, Focal Loss 函数替换交叉熵损失函数, 相较于基准模型, 参数量减少  $3.419 \times 10^7$ , mAP 提高 2.84 个百分点, 召回率增加 3.22 个百分点, FPS 减少 20.53 f/s。通过实际应用发现, 改进模型的 FPS 降低并没有影响到检测性能, 所以从实验结果上看 Ghost-YOLOX-BiFPN 模型在降低参数量的同时提高了对于群养生猪环境下不同大小、不同品种猪只的检测精度。

### 3.3 对比实验

为进一步验证本文提出的 Ghost-YOLOX-BiFPN 模型的有效性, 分别与 YOLOX-L、Faster R-CNN、SSD、YOLO v3、YOLO v5 进行对比, 在相同群养生猪数据集, 相同训练参数下训练 200 轮, 对比实验结果如表 3 所示, 各模型训练损失值和 mAP 变化曲线如图 9、10 所示。

表 3 对比实验结果

Tab. 3 Comparative experiment

模型	mAP/%	参数量	FPS/(f·s <sup>-1</sup> )
YOLOX-L	93.84	$2.334 \times 10^7$	20.14
Faster R-CNN	93.21	$1.371 \times 10^8$	7.48
SSD	83.82	$2.629 \times 10^7$	16.17
YOLO v3	86.74	$6.195 \times 10^7$	36.74
YOLO v5	89.66	$4.663 \times 10^7$	65.56
Ghost-YOLOX-BiFPN	95.80	$2.001 \times 10^7$	40.13

由表 3 可以发现, Ghost-YOLOX-BiFPN 算法相较于一阶段检测算法 YOLO v5、YOLO v3、SSD 和二阶段检测算法 Faster R-CNN, mAP 分别高 6.14、9.06、11.98、2.59 个百分点, 模型参数量分别减少  $2.662 \times 10^7$ 、 $4.194 \times 10^7$ 、 $6.28 \times 10^6$ 、 $1.1708 \times 10^8$ 。Ghost-YOLOX-BiFPN 模型的 mAP 比 YOLOX-L 模型提高 1.96 个百分点, 参数量减少  $3.33 \times 10^6$ , 同时检测速度提高 19.99 f/s。

如图 9 所示, 由于网络训练前 50 轮为冻结训

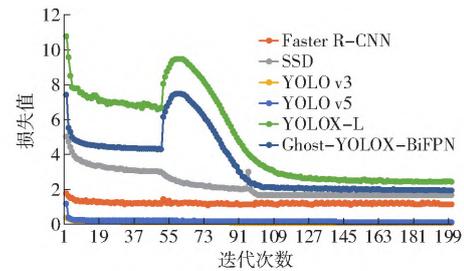


图 9 各模型损失值变化曲线

Fig. 9 Change curves of loss values for each model

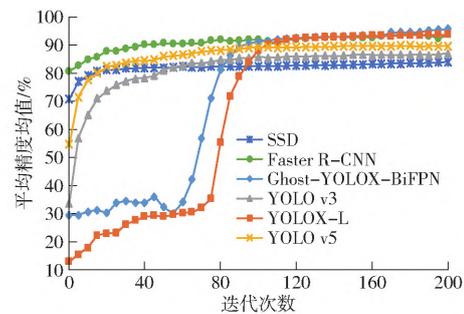


图 10 各模型平均精度均值曲线

Fig. 10 Average accuracy curves of each model

练, 主干部分参数不进行调整, 当迭代次数达到 50 后, 开始解冻训练, 此时损失值出现一个较大的波动。当迭代次数达到 200 时, 各模型损失值下降趋于平稳, 损失曲线逐渐收敛。如图 10 所示, YOLOX-L 和 Ghost-YOLOX-BiFPN 在前期训练中 mAP 较低, 相较于其他网络, YOLOX 系列属于 Anchor free 网络, 没有锚框使得训练中对于目标的位置确定较慢, 所以前期训练精度较低, 但是后期仍能保证精度。Anchor free 机制减小了检测头的复杂度, 使得模型计算量随之减少。训练到 200 轮时, YOLOX、Faster R-CNN、Ghost-YOLOX-BiFPN 平均准确率超过 90%, 本文改进模型 Ghost-YOLOX-BiFPN 以平均精度均值 95.80% 成为各模型中最高, 其在保证检测速度的同时具有更高的精度, 且便于部署到边缘设备, 能够满足群养生猪目标检测的需要。

### 3.4 模型检测效果

图 11 展示了部分数据集在 Faster R-CNN、SSD、YOLO v3、YOLO v5、YOLOX-L、Ghost-YOLOX-BiFPN 上的检测效果。针对图 11a, 可以看出 Faster R-CNN、SSD、YOLO v3、YOLO v5、YOLOX-L 能够识别不同品种、不同大小猪只, 但是对于图 11a 右上角部分小目标出现了不同程度的漏检。针对图 11b, Faster R-CNN 在右上角出现了误检, SSD、YOLO v3、YOLO v5 在左上角出现漏检。针对图 11c, Faster R-CNN 和 YOLOX-L 将背景误判为猪只, SSD 和 YOLO v5 未能识别出右上部分重叠情况下的猪只, YOLO v3 对于图中其他猪只检测效果良好。从实验结果来看, 改进模型 Ghost-YOLOX-

BiFPN 效果较为稳定,对于小目标特征提取能力更强、泛化能力更高,在实验中能够较为准确地识别出粘连、重叠、背景与目标相似度较高等情况下的猪只,适用于复杂的猪圈环境。

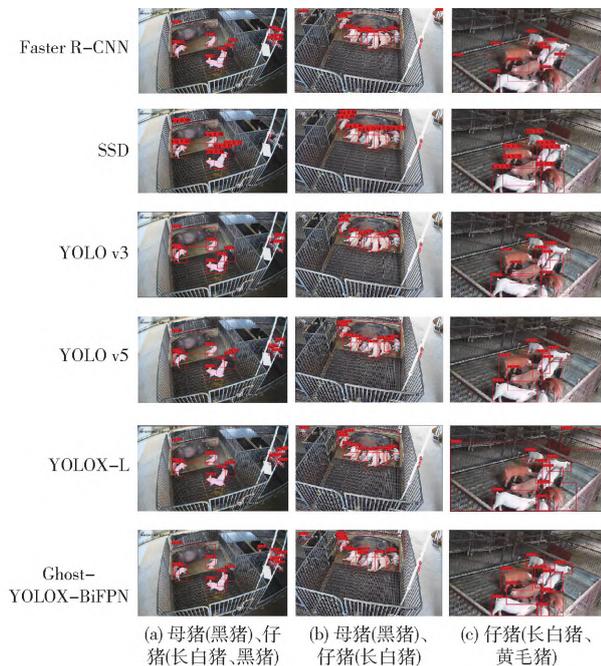


图 11 各模型效果对比

Fig. 11 Comparisons of effects of various models

### 3.5 移动端部署

Jetson Nano 是 Nvidia 研发的基于 GPU 处理器的嵌入式开发板,支持两路 CSI 视频输入接口和 USB 摄像头的输入,拥有 4 GB 内存、16 GB 存储空间。将本文所提出轻量化模型部署到该边缘设备上能够良好运行。Jetson Nano 实物如图 12 所示,性能如图 13 所示。

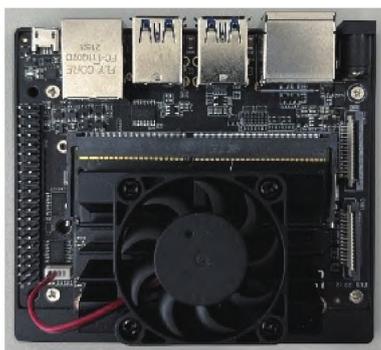


图 12 Jetson Nano 实物图

Fig. 12 Jetson Nano image

为验证模型在 Jetson Nano 上的实际表现,选择参数量较少的 YOLOX-L 模型和 Ghost-YOLOX-BiFPN 模型分别部署到设备上进行比较,随机选取测试集中 100 幅群养生猪图像作为测试指标进行推理测试,推理结果如表 4 所示,部分检测效果对比如图 14 所示。

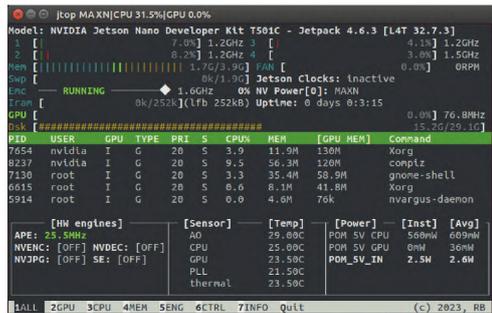


图 13 Jetson Nano 性能展示

Fig. 13 Jetson Nano performance demonstration

表 4 推理结果对比

Tab. 4 Comparison of reasoning situations

模型	猪只实际数量/头	猪只召回数量/头	召回率/%	FPS/(f·s <sup>-1</sup> )
YOLOX-L	1 270	1 193	93.93	8
Ghost-YOLOX-BiFPN	1 270	1 211	95.35	17

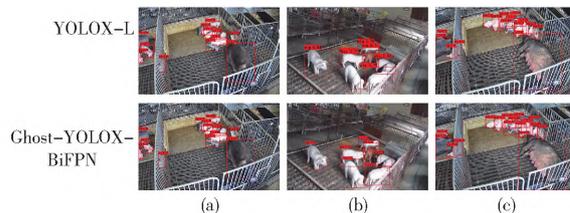


图 14 检测效果对比

Fig. 14 Comparisons of detection effects

图 14 中 YOLOX-L 对图 14a 上部一只处于高度重叠状态下的黑猪未能识别,Ghost-YOLOX-BiFPN 对于图 14a 实现了较为准确的识别。YOLOX-L 对于图 14b 中间猪只重复识别,对于图 14b 右下方部分 2 头正在进食的猪只,由于高度重叠且形状复杂,两种模型都未能准确识别。图 14c 两种模型都实现准确识别。通过在 Jetson Nano 上的对比实验数据可看出,Ghost-YOLOX-BiFPN 模型在边缘设备上检测效果较为稳定,能够实现实时检测,且对于遮挡、重叠等复杂情况都有较好的识别能力,对于不同体型、不同毛色的猪只都可以做到准确识别。

## 4 结论

(1) 针对猪舍这一复杂环境提出了 Ghost-YOLOX-BiFPN 模型,该模型在维持轻量化的同时保证了对不同品种、不同大小猪只的识别能力。在本实验群养生猪测试集上的实验结果表明,改进后模型参数量为  $2.001 \times 10^7$ ,平均精度均值达到 95.80%,召回率达到 94.18%,能够满足群养生猪目标检测。

(2) 提出的 Ghost-YOLOX-BiFPN 模型能够在猪只粘连、重叠、背景目标相似度较高等情况下进行准确识别,检测效果优于 YOLO v5、YOLO v3、

YOLOX-L, 以及主流检测模型 Faster R-CNN、SSD。但是模型对于猪只高度重叠的异常情况的检测效果并不理想。

(3) 将 Ghost-YOLOX-BiFPN 算法部署到移

动端(Jetson Nano)后, 由于移动端处理器性能有限, 导致检测速度降低, 约为 17 f/s, 但仍可以对群养生猪进行实时检测, 满足实际工程应用的需要, 能够为后续建立智能化生猪养殖系统提供支持。

#### 参 考 文 献

- [1] 孙东来, 王继超, 陈科, 等. 基于 Ghost-YOLOv3-2 算法的 2 尺度猪目标检测[J]. 江苏农业科学, 2022, 50(7): 189-196.  
SUN Donglai, WANG Jichao, CHEN Ke, et al. 2-scale pig target detection based on Ghost-YOLOv3-2 algorithm[J]. Jiangsu Agricultural Science, 2022, 50(7): 189-196. (in Chinese)
- [2] SAKIR T, URKMEZ A, INAL S. Determination of body measurements on the Holstein cows using digital image analysis and estimation of live weight with regression analysis[J]. Computers and Electronics in Agriculture, 2011, 76(2): 189-197.
- [3] SAKIR T, URKMEZ A, INAL S. A fuzzy rule-based system for predicting the live weight of Holstein cows whose body dimensions were determined by image analysis[J]. Turkish Journal of Electrical Engineering and Computer Sciences, 2011, 19(4): 689-703.
- [4] OCHOA Z, LUIS E. Evaluation of the accuracy of simple body measurements for live weight prediction in growing-finish pigs [D]. Champaign: University of Illinois at Urbana-Champaign, 2010.
- [5] ENEVOLDSEN C, KRISTENSEN T. Estimation of body weight from body size measurements and body condition scores in dairy cows[J]. Journal of Dairy Science, 1997, 80(9): 1988-1995.
- [6] 李菊霞, 李艳文, 牛帆, 等. 基于 YOLO v4 的猪只饮食行为检测方法[J]. 农业机械学报, 2021, 52(3): 251-256.  
LI Juxia, LI Yanwen, NIU Fan, et al. Pig diet behavior detection method based on YOLO v4[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(3): 251-256. (in Chinese)
- [7] 杨心, 朱伟兴. 基于广义 Hough 聚类的粘连猪头尾识别[J]. 江苏农业科学, 2018, 46(9): 230-235.  
YANG Xin, ZHU Weixing. Recognition of adhesive pig head and tail based on generalized Hough clustering[J]. Jiangsu Agricultural Science, 2018, 46(9): 230-235. (in Chinese)
- [8] 段玉瑶, 马丽, 刘刚. 猪舍场景下的生猪目标跟踪和行为检测方法研究[J]. 农业机械学报, 2015, 46(增刊): 187-193.  
DUAN Yuyao, MA Li, LIU Gang. Target tracking and behavior detection method in piggery scenarios[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(Supp.): 187-193. (in Chinese)
- [9] 马丽, 纪滨, 刘宏申, 等. 单只猪轮廓图的侧视图识别[J]. 农业工程学报, 2013, 29(10): 168-174.  
MA Li, JI Bin, LIU Hongshen, et al. Side view recognition of single pig outline[J]. Transactions of the CSAE, 2013, 29(10): 168-174. (in Chinese)
- [10] 谢双云. 基于图像序列的猪目标检测和跟踪研究[D]. 太原: 太原理工大学, 2015.  
XIE Shuangyun. Research on pig target detection and tracking based on image sequence[D]. Taiyuan: Taiyuan University of Technology, 2015. (in Chinese)
- [11] 朱家骥, 张立生. 基于图像处理的单只猪目标检测方法研究[J]. 信息与电脑(理论版), 2014(24): 11-12.  
ZHU Jiaji, ZHANG Lisheng. Research on single pig target detection method based on image processing[J]. Information and Computer (Theoretical Edition), 2014(24): 11-12. (in Chinese)
- [12] 宁远霖, 杨颖, 李振波, 等. 基于改进 YOLOv5 的复杂跨域场景下的猪个体识别与计数[J]. 农业工程学报, 2022, 38(17): 168-175.  
NING Yuanlin, YANG Ying, LI Zhenbo, et al. Pig individual recognition and counting in complex cross-domain scenarios based on improved YOLOv5[J]. Transactions of the CSAE, 2022, 38(17): 168-175. (in Chinese)
- [13] 燕红文, 刘振宇, 崔清亮, 等. 基于特征金字塔注意力与深度卷积网络的多目标生猪检测[J]. 农业工程学报, 2020, 36(11): 193-202.  
YAN Hongwen, LIU Zhenyu, CUI Qingliang, et al. Multi-target pig detection based on feature pyramid attention and deep convolutional network[J]. Transactions of the CSAE, 2020, 36(11): 193-202. (in Chinese)
- [14] 沈明霞, 太猛, CEDRIC Okinda, 等. 基于深层卷积神经网络的初生仔猪目标实时检测方法[J]. 农业机械学报, 2019, 50(8): 270-279.  
SHEN Mingxia, TAI Meng, CEDRIC Okinda, et al. Real-time detection method of newborn piglets based on deep convolution neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(8): 270-279. (in Chinese)
- [15] ZHAO Hengshuang, SHI Jianping, QI Xiaojuan, et al. Pyramid scene parsing network [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 2881-2890.
- [16] KIRILLOV A, GIRSHICK R, HE K, et al. Panoptic feature pyramid networks [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2019: 6399-6408.
- [17] CHEN Liangjie, ZHU Yukun, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C] // Proceedings of the European Conference on Computer Vision (ECCV), 2018: 801-818.
- [18] GE Z, LIU S, WANG F, et al. YOLOX: exceeding YOLO series in 2021 [J]. ArXiv preprint, arXiv: 2107.08430, 2021.

- [19] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8759 – 8768.
- [20] WOO S, PARK J, LEE J Y, et al. CBAM; convolutional block attention module[C]//Proceedings of the 2018 European Conference on Computer Vision, 2018: 3 – 19.
- [21] TAN M, PANG R, LE Q V. EfficientDet: scalable and efficient object detection[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2020: 10778 – 10787.
- [22] MAO Keyang, KUN Yu, ZHANG Chi, et al. Dense aspp for semantic segmentation in street scenes[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 3684 – 3692.
- [23] WANG Fei, JIANG Mengqing, QIAN Chen, et al. Residual attention network for image classification[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2017: 3156 – 3164.
- [24] YU Changqian, GAO Changxin, WANG Jingbo, et al. BiSeNet: bilateral segmentation network for real-time semantic segmentation[J]. International Journal of Computer Vision, 2021, 129(11): 3051 – 3068.
- [25] ZHAO Ting, WU Xiangqian. Pyramid feature attention network for saliency detection [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2019: 3085 – 3094.
- [26] LIN T Y, GOYAL P, GIRSHICK R. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 318 – 327.

~~~~~

(上接第 179 页)

- [17] 牟媛, 吴振森, 赵豪, 等. 粗糙金属和介质目标的太赫兹散射特性分析[J]. 雷达学报, 2018, 7(1): 83 – 90.  
MOU Yuan, WU Zhensen, ZHAO Hao, et al. The terahertz scattering analysis of rough metallic and dielectric targets[J]. Journal of Radars, 2018, 7(1): 83 – 90. (in Chinese)
- [18] MAREK G, PER M, SPYROS S. Breaking of Huygens-Fresnel principle in inhomogeneous Tomonaga-Luttinger liquids[J]. Journal of Physics A: Mathematical and Theoretical, 2022, 55(5): 107616.
- [19] 陈先冠, 冯利平, 白慧卿, 等. 小麦模型算法集成平台构建与算法比较[J]. 农业机械学报, 2022, 53(6): 237 – 249.  
CHEN Xianguan, FENG Liping, BAI Huiqing, et al. Establishment of wheat model algorithms integration platform and algorithm comparison[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(6): 237 – 249. (in Chinese)
- [20] WANG B, WANG W, FAN J, et al. Modeling of bistatic scattering from an underwater non-penetrable target using a Kirchhoff approximation method[J]. Defence Technology, 2022, 18(7): 1097 – 1106.
- [21] PHILIPP H, CHRISTIAN B, ANDRE L, et al. Analytical solution for the single scattered radiance of two-layered turbid media in the spatial frequency domain. Part 2: vector radiative transfer equation[J]. Optics Communications, 2023, 535(3): 129354.
- [22] KUSTOVA V, KONOSHONKIN V, TIMOFEEV N, et al. Extinction matrix of atmospheric ice crystals with their preferred spatial orientation for the visible and IR regions[J]. Atmospheric and Oceanic Optics, 2019, 32(2): 117 – 123.
- [23] IGNATIOS A, JULES C, ANTHONY G. More on massive gravitino scattering amplitudes and the unitarity cutoff of the new Fayet-Iliopoulos terms[J]. Journal of High Energy Physics, 2023, 2023(4): 4002.
- [24] WANG E, CARCIONE J, BA J, et al. Reflection and transmission of plane elastic waves at an interface between two double-porosity media: effect of local fluid flow[J]. Surveys in Geophysics, 2020, 41(2): 283 – 322.
- [25] 黄波. 基于矢量辐射传输理论的小麦微波散射特性研究[D]. 成都: 电子科技大学, 2014.
- [26] 郭交, 刘健, 宁纪锋, 等. 基于 Sentinel 多源数据的农田地表土壤水分反演模型构建与验证[J]. 农业工程学报, 2019, 35(14): 71 – 78.  
GUO Jiao, LIU Jian, NING Jifeng, et al. Construction and validation of soil moisture retrieval model in farmland based on Sentinel multi-source data[J]. Transactions of the CSAE, 2019, 35(14): 71 – 78. (in Chinese)
- [27] 刘丽标. 含草地粗糙面与目标复合电磁散射研究[D]. 西安: 西安电子科技大学, 2020.
- [28] BINDLISH R, BARROS A P. Parameterization of vegetation backscatter in radar-based, soil moisture estimation[J]. Remote Sensing of Environment, 2001, 76(1): 130 – 137.