



葛绍娟,冀横溢,詹宇,李修松,郑炜超,王涛.改进YOLOv5s后的轻量化猪只姿态识别方法[J].中国农业大学学报,2025,30(05):179-189.
GE Shaojuan,JI Hengyi,ZHAN Yu,LI Xiusong,ZHENG Weichao,WANG Tao. Lightweight pig posture recognition method after improving YOLOv5s[J].
Journal of China Agricultural University, 2025,30(05):179-189.
DOI: 10.11841/j.issn.1007-4333.2025.05.15

改进YOLOv5s后的轻量化猪只姿态识别方法

葛绍娟^{1,2,3} 冀横溢^{1,2,3} 詹宇⁴ 李修松⁴ 郑炜超^{1,2,3*} 王涛⁵

- (1. 中国农业大学 水利与土木工程学院,北京 100083;
2. 农业农村部设施农业工程重点实验室,北京 100083;
3. 北京市畜禽健康养殖环境工程技术研究中心,北京 100083;
4. 大牧人机械(胶州)有限公司,山东 青岛 266300;
5. 山东佳乐家农牧科技有限公司,山东 潍坊 262200)

摘要 针对目前猪只姿态识别精度低、模型复杂性高、检测速度慢等问题,提出一种轻量化猪只姿态识别方法。该方法将基于性能感知的全局通道剪枝算法应用于YOLOv5s模型,识别并剔除原模型中冗余或对性能贡献较小的连接,并对剪枝后的模型进行调参补偿优化。结果表明:剪枝后的YOLOv5s-prune模型在交并比设定阈值为0.5时的平均精度值($mAP_{0.5}$)和交并比在 $[0.5, 0.95]$ 每隔0.05作为1次设定阈值时的多个平均精度均值($mAP_{0.5-0.95}$)上分别达到94.7%和84.6%,相比于原YOLOv5s模型分别高出0.8%和0.4%;其参数量和每1s浮点运算次数(FLOPs)分别为 3.9×10^6 和 10.9×10^9 ,较原YOLOv5s模型分别降低了 3.1×10^6 和 5.3×10^9 ;对每张图片的推理时间达到3.6 ms,较原YOLOv5s模型提高1.1 ms。相比于Faster R-CNN、CenterNet、YOLOv3-SPP、YOLOXs、YOLOv8s、YOLOv10s、YOLOv11s目标检测模型,参数量分别减少了 132.8×10^6 、 28.2×10^6 、 100.8×10^6 、 5.0×10^6 、 7.2×10^6 、 4.2×10^6 和 5.5×10^6 ,FLOPs分别减少了 143.9×10^9 、 79.4×10^9 、 272.9×10^9 、 16.3×10^9 、 18×10^9 、 14.3×10^9 和 11.1×10^9 ,对每张图片的推理时间分别提高了25.4、20.4、35.2、1.5、3.9、4.2和1.8 ms。在单栏饲养12、8和6头猪的场景下,检测性能优于YOLOv5s。本研究提出的方法不仅减少了模型参数量和计算量,提高了检测速度,而且有效地增加了识别精度,可以满足猪场实际生产中对猪只姿态行为快速准确识别的需求。

关键词 猪;姿态行为识别;深度学习;通道剪枝

中图分类号 S828;TP391.41

文章编号 1007-4333(2025)05-0179-11

文献标志码 A

Lightweight pig posture recognition method after improving YOLOv5s

GE Shaojuan^{1,2,3}, JI Hengyi^{1,2,3}, ZHAN Yu⁴, LI Xiusong⁴, ZHENG Weichao^{1,2,3*}, WANG Tao⁵

(1. College of Water Resources and Civil Engineering, China Agricultural University, Beijing 100083, China;

2. Key Laboratory of Agricultural Engineering in Structure and Environment of Ministry of Agriculture and Rural Affairs,
Beijing 100083, China;

3. Beijing Engineering Research Center for Animal Healthy Environment, Beijing 100083, China;

4. Big Herdsman Machinery (Jiaozhou) Co., Ltd., Qingdao 266300, China;

5. Shandong Jialejia Agriculture and Animal Husbandry Technology Co., Ltd., Weifang 262200, China)

Abstract To address the issues of low accuracy, high model complexity, and slow detection speed that

收稿日期: 2024-08-03

基金项目: 2023青岛市科技惠民示范专项(23-2-8-xdny-3-nsh);山东省重点研发计划(2022S1203-00337)

第一作者: 葛绍娟(ORCID: 0009-0005-7633-0342),博士研究生,E-mail: geshaojuan@cau.edu.cn

通讯作者: 郑炜超(ORCID: 0000-0002-0719-9775),教授,博士生导师,主要从事畜禽养殖精准环控技术、智能养殖装备相关研究,E-mail: weichaizheng@cau.edu.cn

existed in current pig posture recognition tasks, a lightweight pig pose recognition method is proposed in this study. This method applies the performance-aware global channel pruning algorithm to the YOLOv5s model, identifies and removes redundant or less contributions to performance in the original model, and performs parameter adjustment compensation optimization on the pruned model. The results indicate that: The YOLOv5s-prune model achieved an average precision value ($mAP_{0.5}$) of 94.7% at an intersection over union (IoU) threshold of 0.5, and reached an average precision mean ($mAP_{0.5-0.95}$) of 84.6% with multiple IoU thresholds set at intervals of 0.05 between [0.5, 0.95], which were 0.8% and 0.4% higher compared to the original YOLOv5s model, respectively. Furthermore, the number of parameters and the number of floating-point operations per second (FLOPs) were 3.9×10^6 and 10.9×10^9 , respectively, which were 3.1×10^6 and 5.3×10^9 lower than those of the original YOLOv5s model; The model achieved an inference speed of 3.6 ms, representing an improvement of 1.1 ms over the original model. Compared to other object detection models including Faster R-CNN, CenterNet, YOLOv3-SPP, YOLOXs, YOLOv8s, YOLOv10s and YOLOv11s, the model constructed in this study reduced the parameter count by 132.8×10^6 , 28.2×10^6 , 100.8×10^6 , 5.0×10^6 , 7.2×10^6 , 4.2×10^6 and 5.5×10^6 , decreased the FLOPs by 143.9×10^9 , 79.4×10^9 , 272.9×10^9 , 16.3×10^9 , 18×10^9 , 14.3×10^9 and 11.1×10^9 , improved the detection time of each graph by 25.4, 20.4, 35.2, 1.5, 3.9, 4.2 and 1.8 ms, respectively. The detection performance of the model was better than that of YOLOv5 s in the scenario of feeding 12, 8 and 6 pigs in a single column. In summary, the proposed method not only reduces model parameters and computational complexity but also enhances detection speed and recognition accuracy. Therefore, the new method presented in this study effectively meets the requirements of pig posture recognition in practical pig farming scenarios.

Keywords pig; posture behavior recognition; deep learning; channel pruning

对猪只姿态进行实时识别和监测,有助于及时了解猪只的健康状况,提前识别可能危及其健康的因素^[1],从而提升养殖场的管理效率,改善动物福利和健康水平,对于养殖场实现精细化管理至关重要^[2-3]。目前,随着计算机视觉技术的发展,凭借其无接触式广泛捕捉信息的优势^[4],该技术已成功应用于猪只的日常饮水、采食以及争斗等行为的监测,有力地推动了养殖产业的发展^[5-7]。

深度学习利用多层神经网络对数据进行特征学习,能够捕捉图像数据中更高层次的抽象表示,并自动从中提取特征^[8],已有研究将深度学习技术应用于猪只姿态行为识别中。例如,在深度学习框架上引入了Faster R-CNN用于识别哺乳母猪的姿态^[9];通过改进的双流RGB-D Faster R-CNN算法来自动识别母猪姿态^[10];基于CNN的方法来检测深度视频中母猪的姿态动态变化^[11]等方法,但以上的姿态识别均基于深度相机拍摄的图像,成本较高。为降低成本,近年来2D相机也逐渐应用到对群养育肥猪的站立和躺卧姿态进行识别技术中,Nasirahmadi等^[12]通过结合R-FCN与ResNet101检测猪只站立、侧卧和俯卧。Riekert等^[13-14]通过改进Faster R-CNN来检测猪只的位置和识别猪只的躺卧和非躺卧姿态。Shao等^[15]通过YOLOv5从猪群

图片中提取个体猪,然后使用DeepLab v3+语义分割方法提取猪的个体轮廓并采用深度可分离卷积网络识别猪只站立、俯卧、侧卧和探索姿态。Ji等^[16]使用改进后的YOLOX识别猪只姿态行为,并使用简化后的copy paste和标签平滑策略解决数据集中猪只坐姿过少的类别不均衡问题。Xu等^[17]使用深度图像和CNN-SVM模型对商业条件下猪的多种姿势(站立、坐立、胸卧、腹卧和侧卧)进行识别和评分。

目前基于深度学习的姿态识别方法在精度上已经取得显著的进展;然而这些方法通常使用复杂的深度学习模型,虽然提供了高准确性,但也带来了模型体积庞大和计算资源消耗高的问题,在某些猪场实际应用场景下难以满足实时性和边缘部署等需求^[18]。针对模型过大和复杂度高的问题,模型通道剪枝是一种旨在降低深度学习模型复杂度、降低模型的参数数量和计算量,且不损害模型的性能的技术^[19-21]。该技术可以通过去除模型中不必要的参数、连接或通道,以减少模型的复杂性,从而实现模型轻量化的目标^[20-21]。

为优化猪只姿态行为识别任务,本研究拟选用运行结果稳定且能够灵活应用的YOLOv5目标检测模型作为基础,探索使用通道剪枝算法减少模型

中的不必要参数和通道,以实现模型的轻量化,克服YOLOv5模型在目标检测任务中存在的冗余通道和模型较大等问题,为实现准确、快速的猪只姿态行为识别提供参考。

1 材料与方法

1.1 试验地点及数据采集场景

试验地点位于重庆市某猪舍,舍内共有50栏猪圈,圈栏尺寸为4.2 m×2.5 m,每个栏内设置有1个采食槽和4个饮水器,圈栏地面为半漏缝地板结构,漏缝地板的宽度为1.2 m。

每个圈栏内饲养的猪只数量不同,会影响采集图像中猪只目标信息的质量,从而导致模型在不同场景下的运行效果存在较大差异。因此本研究中视频和图片数据按照单栏不同猪只数量的饲养场景进行分段采集:2020年6月,采集单栏饲养6头猪场景;2022年2—3月,单栏饲养12头猪;2022年6月,单栏饲养7头猪;2022年8月,单栏饲养8头猪。猪舍内每天8:00和14:00人工加料。

1.2 试验数据

在猪舍顶部安装高清2D广角摄像头(3346P1-1,杭州海康威视数字技术股份有限公司),摄像头连接至带有4T硬盘的硬盘录像机实现录像,每隔

1天进行1次完整的录制,共采集15天视频数据进行挑选。对采集到的不同时间段和不同场景下的视频进行抽帧处理,为了防止数据重复度过高,每隔20 s抽取1张视频帧图像,图片尺寸1 280像素×720像素。本研究共选取3种猪只姿态进行检测,包括猪只的站立、躺卧和坐立姿态^[22-23]。其中站立姿态定义为“身体与四肢垂直,背朝上,腹部朝下,腿部伸直,猪蹄接触地面”;躺卧姿态定义为“躯干与地面完全接触,腿部弯曲或伸展”;坐立姿态定义为“身体部分垂直于伸展的前腿,尾部接触地面”。人工对图像集进行审查,删去相似的图像、猪只姿态不变化和猪只模糊的图像,保证图像内的猪只位置的准确性和猪只姿态的多样性,共收集2 993张包含猪只姿态的图像组成数据集。

为了获取猪只位置及姿态信息,训练出更精确的模型,需要对采集到的图片进行数据标注。本研究使用开源工具Labelimg进行图像数据标注,并保存为YOLO所需格式的标注文件,每标记完成1张图片后会生成1个同名的txt文件,该文件内记录了图像内目标猪只的姿态类别及标注矩形框的中心坐标、框高和框宽。对标注完成的数据集按7:2:1的数量比划分为训练集、验证集、测试集。2 993张图片标注完成后共有22 956个标注,猪只不同姿态数据集标注分布见表1。

表1 猪只不同姿态数据集标注分布

Table 1 Label distribution of pig different posture data sets

个

姿态 Posture	训练集 Train set	验证集 Val set	测试集 Test set	总计 Total
站立 Standing	4 898	1 313	644	6 855
躺卧 Lying	10 058	2 975	1 450	14 483
坐立 Sitting	1 144	316	158	1 618
总计 Total	16 100	4 604	2 252	22 956

1.3 YOLOv5s模型


YOLOv5使用不同的宽度因子和深度因子将模型从小到大划分为YOLOv5n、YOLOv5s、YOLOv5m、YOLOv5l、YOLOv5x,由于设备限制,本研究使用的版本为YOLOv5s。

YOLOv5提供了多种线上数据增强方法。本研究使用的数据增强方法主要有以下4种:1)随机调整训练集中图像的色度、饱和度和明度;2)随机对训练集中的图像进行仿射变换;3)随机对训练集

中的图像进行翻转;4)随机将训练集中的4张图片按照中心点嵌合为1张图片。通过以上方式可以有效增加数据集的多样性,提高模型的泛化能力。YOLOv5s模型具体架构见图1。

本研究中YOLOv5s训练时使用随机梯度下降法、动量和学习率热身策略。模型的批大小设置为64,共训练300个迭代轮次;设置初始学习率为0.01,最终学习率为0.002;动量0.937,权重衰减系数0.000 5;对前3个轮次进行学习率热身,学习率

式中: t 为YOLOv5s的任务编号; $\Delta L_t(\theta)$ 为第 t 个任务在剪枝选择 θ 下的相对损失变化。



FLOPs为每s浮点运算次数; λ 为FLOPs阈值下降的恒定比率。
FLOPs refer to the number of floating-point operations per second;
 λ is a constant ratio of threshold decrease for FLOPs.

图2 YOLOv5s模型全局通道剪枝技术路线

Fig. 2 YOLOv5s model global channel pruning technical route

对显著性指标低的候选层进行剪枝的同时保证该层对应的任务相对性能不出现下降,以此得到该层的剪枝率集合;选择每个候选层剪枝率集合中最高剪枝率,将要剪枝的候选层作为剪枝层集。按照剪枝层集在YOLOv5s中进行检索,以该层的剪枝率进行通道剪枝,得到剪枝后的YOLOv5s-prune模型。再使用迁移学习对YOLOv5s-prune重新训练后进行后续试验,迭代次数为300次。

1.5 模型验证指标

本研究使用目标检测算法中广泛使用的4个评价指标:参数量、FLOPs、推理时间和平均精度均值。

- 1)参数量指模型包含的参数数量;
- 2)FLOPs为每s的浮点运算次数;

3)推理时间指推理1张图片需要的时间;

4)平均精度均值需要根据图像交并比的阈值设定确定,计算过程如下:

①首先计算图像交并比(IoU)。交并比用来衡量真实图像框和预测图像框面积重叠的程度,计算公式为:

$$\text{IoU} = \frac{A \cap B}{A \cup B} \quad (4)$$

式中: A 、 B 分别表示采用人工标注的真实框和本研究算法得到的预测框的图像面积。

②根据IoU计算模型的精确率和召回率。精确率(P)的计算公式为:

$$P = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (5)$$

式中: TP 为 $\text{IoU} \geq$ 设定阈值的检测框数量; FP 为 $\text{IoU} <$ 设定阈值的检测框数量。

召回率(R)的计算公式为:

$$R = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (6)$$

式中: FN 为未被检测到的真实框数量。

③计算平均精度均值。在实际应用中,需要针对每个 R 值计算出与之对应的最大的 P 值,并分别以 R 和 P 为横纵坐标绘制曲线(P - R 曲线)。平均精度(AP)是指某一IoU设定阈值下的 P - R 曲线下与 x 轴之间面积的近似值,计算公式为:

$$\text{AP} = \int_0^1 P(R) dR \times 100\% \quad (7)$$

平均精度均值 mAP 指不同IoU设定阈值下的 AP 均值,本试验采用 $\text{mAP}_{0.5}$ 和 $\text{mAP}_{0.5-0.95}$ 作为模型评价指标,分别表示IoU阈值设定为0.5的 AP 值和IoU的阈值从 $[0.5, 0.95]$ 每隔0.05步长计算1次 AP 的均值。 mAP 的计算公式如下:

$$\text{mAP} = \frac{1}{m} \left(\sum_{x=1}^m \text{AP}_x \right) \times 100\% \quad (8)$$

式中: m 为IoU阈值设定的数量,即对于 $\text{mAP}_{0.5}$ 和 $\text{mAP}_{0.5-0.95}$, m 分别为1和10; x 为IoU阈值设定的序号。

2 结果与讨论

2.1 YOLOv5s在姿态行为上的识别结果

图3示出训练过程中YOLOv5s在验证集上的精度变化。YOLOv5s在 $\text{mAP}_{0.5}$ 和 $\text{mAP}_{0.5-0.95}$ 指标上变化趋势近似,在迭代至180次后趋于收敛。选择验证

集中性能最优的模型权重用以后续试验,其 $mAP_{0.5}$ 和 $mAP_{0.5-0.95}$ 分别达到95.1%和85.5%。在测试集上该模型权重的 $mAP_{0.5}$ 和 $mAP_{0.5-0.95}$ 分别为93.9%和84.2%,低于在验证集上的结果,存在一定的过拟合现象。此外,YOLOv5s的参数量为 7×10^6 ,FLOPs为 15.8×10^9 ,每张图片的推理时间为4.7 ms。




图3 训练过程中YOLOv5s在验证集上的平均精度均值(mAP)

Fig. 3 Mean average precision(mAP) change in YOLOv5s on the verification set during training process

2.2 全局通道剪枝后的识别结果

在基于性能感知的全局通道剪枝算法中,初始值损失和总体性能损失的阈值是2个关键的超参数,用于平衡模型的剪枝率和性能:初始值损失表示模型在开始训练时预测结果与真实标签之间差异程度的一个量化指标;总体性能损失阈值则是指在整个训练过程中,模型预测结果与真实标签之间差异程度所能接受的最大界限,如果模型的损失值低于这个阈值,则认为模型性能良好;如果高于这个阈值,则可能需要进一步调整模型结构或优化算法。

为提高模型精确度,降低模型复杂度和参数量,缩短模型训练及计算时间,本研究通过调整损失函数参数的方式对剪枝后的YOLOv5-prune模型进行优化,每次调参后进行300次迭代的迁移学习,然后选择验证集上性能表现最优的模型权重进行测试,详细训练过程及训练参数见1.3。

表2为YOLOv5s-prune模型调整损失函数参数后的测试结果,可以看出:大部分剪枝条件下的YOLOv5s-prune在 $mAP_{0.5}$ 和 $mAP_{0.5-0.95}$ 上的检测结

表2 YOLOv5s-prune模型调整损失函数参数后的测试结果
Table 2 Test results of YOLOv5s-prune model after adjusting loss function parameters

初始值损失 Initial value loss	总体性能损失 Overall performance loss	$mAP_{0.5}/\%$	$mAP_{0.5-0.95}/\%$	参数量/ 10^6 Parameters	FLOPs/ 10^9	推理时间/ms Inference time
0.02	2	94.5	84.5	5.1	12.9	4.8
0.04	4	94.4	84.4	4.6	11.9	4.6
0.06	6	94.4	84.4	5.6	12.8	4.7
0.08	8	94.1	84.0	4.1	11.2	4.2
0.10	10	94.3	84.1	3.8	10.8	4.3
0.12	12	94.4	84.3	4.0	11.0	4.3
0.14	14	94.3	84.3	4.0	10.7	4.0
0.16	16	94.7	84.6	3.9	10.5	3.6
0.18	18	94.0	84.7	3.9	10.4	3.6
0.20	20	94.5	94.2	3.9	10.4	3.8
0.22	22	94.0	83.7	4.1	10.6	5.4
0.24	24	94.4	84.1	4.1	10.6	4.1
0.26	26	93.3	82.6	4.1	10.4	3.6

注: $mAP_{0.5}$ 和 $mAP_{0.5-0.95}$ 分别表示IoU阈值分别为0.5和[0.5,0.95]的平均精度均值;FLOPs为每s浮点运算次数。表3同。
Note: $mAP_{0.5}$ and $mAP_{0.5-0.95}$ represent mean average precision of IoU thresholds of 0.5 and [0.5,0.95], respectively. FLOPs refer to the number of floating-point operations per second. The same as Table 3.

果都优于 YOLOv5s 模型;在 $mAP_{0.5}$ 和 $mAP_{0.5-0.95}$ 最高分别达到 94.7% 和 84.7%,较 YOLOv5s 分别提高 0.8% 和 0.5%。此外,剪枝后的 YOLOv5s-prune 模型的参数数量最低可以减少到 3.8×10^6 , FLOPs 最低可以减少到 10.4×10^9 。对每张图片的推理时间也得到缩短,最快达到 3.6 ms,比 YOLOv5s 模型快 1.1 ms。

综合考虑各个指标后,选择初始值损失和总体性能损失阈值分别为 0.16 和 16 的 YOLOv5s-prune

作为后续试验的模型。该模型在检测精度方面表现出较高的性能,同时模型复杂度也接近最低值。

图 4 示出全局通道剪枝后 YOLOv5s 和 YOLOv5s-prune 模型各卷积层通道数变化。可见,通道数普遍有所下降,其中下降明显的卷积层主要集中在模型的第 16 层之后,表明在 YOLOv5s 模型中,骨干网络的中后部分和颈部网络存在大量冗余通道。通过采用该剪枝算法能够有效地提升模型的效率。




图 4 全局通道剪枝后的 YOLOv5s 和 YOLOv5s-prune 模型各卷积层通道数变化

Fig. 4 The number of channels in each convolutional layer of YOLOv5s and YOLOv5s-prune models after global channel pruning changes

2.3 不同目标检测模型对猪只姿态的识别结果

为验证本研究提出方法的有效性,将 YOLOv5

s-prune 与目前主流的目标检测模型进行对比。表 3 示出 YOLOv5s-prune 与 Faster R-CNN、CenterNet、

表 3 YOLOv5s-prune 与其他目标检测模型的性能对比结果

Table 3 Performance comparison between YOLOv5s-prune and other target detection models

模型名称 Model name	$mAP_{0.5}/\%$	$mAP_{0.5-0.95}/\%$	参数量/ 10^6 Parameters	FLOPs / 10^9	推理时间/ms Inference time
Faster-RCNN	94.1	81.4	136.7	154.4	29.0
CenterNet	95.3	83.2	32.1	89.9	24.0
YOLOv3-SPP	93.7	84.7	104.7	283.4	38.8
YOLOXs	94.4	83.9	8.9	26.8	5.1
YOLOv8s	94.2	84.8	11.1	28.7	7.5
YOLOv5s	93.9	84.2	7.0	15.8	4.7
YOLOv10s	94.4	84.0	8.1	24.8	7.8
YOLOv11s	94.5	84.4	9.4	21.6	5.4
YOLOv5s-prune	94.7	84.6	3.9	10.5	3.6

YOLOv3-SPP、YOLOXs、YOLOv5s、YOLOv8s、YOLOv10s和YOLOv11s在猪只姿态识别性能上的对比结果。可以看出YOLOv5s-prune在参数量、FLOPs和推理时间上均优于其他模型;相较于参数量最高的Faster-RCNN减少 132.8×10^6 ,在FLOPs和推理时间上较YOLOv3-SPP分别减少 272.9×10^9 和34.8 ms。在 $mAP_{0.5}$ 上CenterNet的检测精度最高,较YOLOv5s-prune高出0.6%;但在 $mAP_{0.5-0.95}$ 上YOLOv5s-prune相较于CenterNet高1.4%,表现出了更好的性能。在 $mAP_{0.5-0.95}$ 上YOLOv8s相比于YOLOv5s-prune略高出0.2%,但在 $mAP_{0.5}$ 上低0.5%。综上所述,本研究提出的方法在大幅度降低模型复杂度的情况下,可以有效提高猪只姿态识别的检测精度。

2.4 不同场景下的姿态行为识别结果

表4示出YOLOv5s和YOLOv5s-prune对不同场景猪只姿态的识别结果。本研究测试集的300张图片中,单栏饲养12、8、7和6头猪场景下的图片数量分别为50、55、20和175张。

在单栏12头猪场景下,YOLOv5s和YOLOv5s-prune对站立和躺卧姿态的检测精度都较高;但在坐立姿态的识别结果中,YOLOv5s-prune的 $mAP_{0.5}$

和 $mAP_{0.5-0.95}$ 较YOLOv5s分别高10.2%和9.6%。猪只头数增多会导致猪只之间遮挡、重叠等情况变多,以上结果说明YOLOv5s-prune在复杂场景下的检测性能要远远优于YOLOv5s。

单栏8头猪时,YOLOv5s在站姿识别上的 $mAP_{0.5}$ 和 $mAP_{0.5-0.95}$ 较YOLOv5s-prune分别高0.5%和2.3%;但YOLOv5s-prune在躺卧姿态识别中的 $mAP_{0.5}$ 和 $mAP_{0.5-0.95}$ 较YOLOv5s分别高0.8%和0.2%,在坐立姿态识别中的 $mAP_{0.5}$ 和 $mAP_{0.5-0.95}$ 较YOLOv5s分别高0.7%和0.2%。

单栏7头猪时,YOLOv5s-prune在站立和躺卧姿态的中的检测精度均劣于YOLOv5s,仅在对坐立姿态的识别中占有优势。YOLOv5s总计在 $mAP_{0.5}$ 和 $mAP_{0.5-0.95}$ 较YOLOv5s分别高0.7%和0.1%。

单栏6头猪时,YOLOv5s和YOLOv5s-prune在躺卧姿态识别中性能近似;在站立姿态识别中,YOLOv5s-prune的 $mAP_{0.5}$ 和 $mAP_{0.5-0.95}$ 较YOLOv5s分别高2.8%和1.8%;在坐立姿态识别中,YOLOv5s的 $mAP_{0.5}$ 和 $mAP_{0.5-0.95}$ 较YOLOv5s-prune分别高1.2%和1.1%。

YOLOv5s-prune在单栏饲养12、8、6头猪的场

表4 YOLOv5s和YOLOv5s-prune对不同场景猪只姿态的识别结果
Table 4 Comparison of recognition results of YOLOv5s and YOLOv5s-prune in different scenarios


猪只数量 Pig number	模型 Model	姿态 Posture	$mAP_{0.5}/\%$	$mAP_{0.5-0.95}/\%$	猪只数量 Pig number	模型 Model	姿态 Posture	$mAP_{0.5}/\%$	$mAP_{0.5-0.95}/\%$
12	YOLOv5s	站立	99.0	85.0	7	YOLOv5s	站立	97.2	92.2
		躺卧	98.5	82.9			躺卧	98.2	91.6
		坐立	47.9	36.6			坐立	90.6	84.3
		总计	81.8	68.2			总计	95.4	89.3
	YOLOv5s-prune	站立	99.0	84.3		YOLOv5s-prune	站立	95.7	89.9
		躺卧	98.8	83.1			躺卧	97.8	91.4
		坐立	58.1	46.2			坐立	90.6	86.3
		总计	85.3	71.2			总计	94.7	89.2
8	YOLOv5s	站立	96.6	88.8	6	YOLOv5s	站立	93.3	82.4
		躺卧	97.7	91.7			躺卧	98.2	89.3
		坐立	93.2	85.5			坐立	87.9	79.1
		总计	95.8	88.7			总计	93.1	83.6
	YOLOv5s-prune	站立	96.1	86.5		YOLOv5s-prune	站立	96.1	84.2
		躺卧	98.5	91.9			躺卧	98.4	89.3
		坐立	93.9	87.5			坐立	86.7	78.0
		总计	96.2	88.6			总计	93.7	83.8

景下识别性能均优于YOLOv5s;仅在单栏7头猪场景下的性能表现欠佳,可能是由于单栏7头猪的场景下图片数较少,YOLOv5s-prune在剪枝后通道变少,导致特征提取能力变弱,会因缺乏足够的信息而导致准确率下降;此外,在数据量有限的情况下,YOLOv5s在训练的过程中可能采取了更为有效的策略,YOLOv5s-prune的剪枝虽然减少了模型参数,但可能会使得其在这类特定情况下的表现不如YOLOv5s。综上所述,本研究提出的YOLOv5s-prune在多数场景下,可以快速、准确地完成猪只姿态识别任务。

2.5 YOLOv5s-prune 错误识别结果的可视化分析

图5示出YOLOv5s-prune对不同场景猪只姿态

的错误识别结果示例。YOLOv5s-prune可以检测出所有猪只的位置,但对于具体类别的区分性能不足。在12头和8头的场景中,错误识别均由于坐立和躺卧无法被正确区分,导致出现了2个不同类别的检测框。在7头和6头的场景中,错误识别是因为无法准确识别站立姿态,也导致出现了2个不同类别的检测框。以上结果说明,YOLOv5s-prune在分辨姿态的类别上仍有较大的提升空间。由于猪大部分时间都处于躺卧姿态,站立和坐立姿态的标注数量远少于躺卧的标注数量,不同姿态之间的标注数量严重不均衡,模型可以学习到躺卧和站立的特征远远多于坐立,因此如何解决类别数量不均衡是未来姿态识别模型精度进一步提升的重要方向。



绿色框为错误姿态识别结果,红色、粉色、橙色框分别为站立、躺卧、坐立姿态识别结果。

Green boxes are the results of wrong posture recognition in the pictures, and red, pink, and orange boxes are the results of standing, lying, and sitting posture recognition respectively.

图5 YOLOv5s-prune 对不同场景猪只姿态的错误识别结果示例

Fig. 5 Examples of error recognition results of pig posture by YOLOv5s-prune in different scenarios

3 结论

本研究针对猪只姿态行为识别对快速性和准确性的需求,采用基于性能感知的全局通道剪枝算法,将其应用于YOLOv5s模型,提出了一种轻量化的猪只姿态行为识别方法。经过剪枝后,YOLOv5s-prune模型在 $mAP_{0.5}$ 和 $mAP_{0.5-0.95}$ 这2个指标上分别达到94.7%和84.6%,相较于原始的YOLOv5s模型分别

提高了0.8%和0.4%。此外,模型参数量和每s浮点运算次数(FLOPs)分别减少了 3.1×10^6 和 5.3×10^9 ,且对每张图片的推理时间缩短了1.1 ms,达到3.6 ms。与其他目标检测模型如Faster R-CNN、CenterNet、YOLOv3-SPP、YOLOXs、YOLOv8s、YOLOv10s、YOLOv11s目标检测模型,该方法在参数量和计算量方面都表现出显著的优势,参数量分别减少了 132.8×10^6 、 28.2×10^6 、 100.8×10^6 、 5×10^6 、 7.2×10^6 、 4.2×10^6

和 5.5×10^6 , FLOPs 分别减少了 143.9×10^9 、 79.4×10^9 、 272.9×10^9 、 16.3×10^9 、 18×10^9 、 14.3×10^9 和 11.1×10^9 ; 同时, 对每张图片的推理时间分别缩短了 25.4、20.4、35.2、1.5、3.9、4.2 和 1.8 ms。在单栏饲养 12、8 和 6 头猪的场景下, 该方法的检测性能优于 YOLOv5s 模型。通过对 YOLOv5s-prune 的错误识别结果分析得出解决猪只姿态行为之间的类别不平衡是未来的研究方向之一。综上, 本研究提出的方法不仅有效地减少了模型的参数量和计算量, 提高了检测速度, 而且提高了识别精度, 满足实际猪场生产中对猪只姿态行为识别的需求。

参考文献 References

- [1] Xu J Y, Zhou S Y, Xia F, Xu A J, Ye J H. Research on the lying pattern of grouped pigs using unsupervised clustering and deep learning [J]. *Livestock Science*, 2022, 260: 104946
- [2] Yang Q M, Xiao D Q. A review of video-based pig behavior recognition [J]. *Applied Animal Behaviour Science*, 2020, 233: 105146
- [3] Ellis J L, Jacobs M, Dijkstra J, van Laar H, Cant J P, Tulpan D, Ferguson N. Review: Synergy between mechanistic modelling and data-driven models for modern animal production systems in the era of big data [J]. *Animal*, 2020, 14(S2): s223-s237
- [4] Chen C, Zhu W X, Norton T. Behaviour recognition of pigs and cattle: Journey from computer vision to deep learning [J]. *Computers and Electronics in Agriculture*, 2021, 187: 106255
- [5] 傅隆生, 宋珍珍, Zhang Xin, 李瑞, 王东, 崔永杰. 深度学习方法在农业信息中的研究进展与应用现状 [J]. 中国农业大学学报, 2020, 25(2): 105-120
- Fu L S, Song Z Z, Zhang X, Li R, Wang D, Cui Y J. Applications and research progress of deep learning in agriculture [J]. *Journal of China Agricultural University*, 2020, 25(2): 105-120 (in Chinese)
- [6] 滕光辉, 冀横溢, 庄晏榕, 刘慕霖. 深度学习在猪只饲养过程的应用研究进展 [J]. 农业工程学报, 2022, 38(14): 235-249
- Teng G H, Ji H Y, Zhuang Y R, Liu M L. Research progress of deep learning in the process of pig feeding [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2022, 38(14): 235-249 (in Chinese)
- [7] Li G M, Huang Y B, Chen Z Q, Chessier G D Jr, Purswell J L, Linhoss J, Zhao Y. Practices and applications of convolutional neural network-based computer vision systems in animal farming: A review [J]. *Sensors*, 2021, 21(4): 1492
- [8] LeCun Y, Bengio Y, Hinton G. Deep learning [J]. *Nature*, 2015, 521: 436-444
- [9] Zheng C, Zhu X M, Yang X F, Wang L N, Tu S Q, Xue Y J. Automatic recognition of lactating sow postures from depth images by deep learning detector [J]. *Computers and Electronics in Agriculture*, 2018, 147: 51-63
- [10] Zhu X M, Chen C X, Zheng B, Yang X F, Gan H M, Zheng C, Yang A Q, Mao L, Xue Y J. Automatic recognition of lactating sow postures by refined two-stream RGB-D faster R-CNN [J]. *Biosystems Engineering*, 2020, 189: 116-132
- [11] Yang X F, Zheng C, Zou C H, Gan H M, Li S M, Huang S M, Xue Y J. A CNN-based posture change detection for lactating sow in untrimmed depth videos [J]. *Computers and Electronics in Agriculture*, 2021, 185: 106139
- Yang X F, Zheng C, Zou C H, Gan H M, Li S M, Huang S M, Xue Y J. A CNN-based posture change detection for lactating sow in untrimmed depth videos [J]. *Computers and Electronics in Agriculture*, 2021, 185: 106139
- [12] Nasirahmadi A, Sturm B, Edwards S, Jeppsson K H, Olsson A C, Müller S, Hensel O. Deep learning and machine vision approaches for posture detection of individual pigs [J]. *Sensors*, 2019, 19(17): 3738
- [13] Rieker M, Klein A, Adrien F, Hoffmann C, Gallmann E. Automatically detecting pig position and posture by 2D camera imaging and deep learning [J]. *Computers and Electronics in Agriculture*, 2020, 174: 105391
- [14] Rieker M, Opderbeck S, Wild A, Gallmann E. Model selection for 24/7 pig position and posture detection by 2D camera imaging and deep learning [J]. *Computers and Electronics in Agriculture*, 2021, 187: 106213
- [15] Shao H M, Pu J Y, Mu J. Pig-posture recognition based on computer vision: Dataset and exploration [J]. *Animals*, 2021, 11(5): 1295
- [16] Ji H Y, Yu J H, Lao F D, Zhuang Y R, Wen Y B, Teng G H. Automatic position detection and posture recognition of grouped pigs based on deep learning [J]. *Agriculture*, 2022, 12(9): 1314
- [17] Xu J Y, Zhou S Y, Xu A J, Ye J H, Zhao A Y. Automatic scoring of postures in grouped pigs using depth image and CNN-SVM [J]. *Computers and Electronics in Agriculture*, 2022, 194: 106746
- [18] 王政, 许兴时, 华志新, 尚钰莹, 段援朝, 宋怀波. 融合 YOLOv5n 与通道剪枝算法的轻量化奶牛发情行为识别 [J]. 农业工程学报, 2022, 38(23): 130-140
- Wang Z, Xu X S, Hua Z X, Shang Y Y, Duan Y C, Song H B. Lightweight recognition for the oestrus behavior of dairy cows combining YOLO v5n and channel pruning [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2022, 38(23): 130-140 (in Chinese)
- [19] Luo J H, Zhang H, Zhou H Y, Xie C W, Wu J X, Lin W Y. ThiNet: Pruning CNN filters for a thinner net [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2019, 41(10): 2525-2538
- [20] Yu R C, Li A, Chen C F, Lai J H, Morariu V I, Han X T, Gao M F, Lin C Y, Davis L S. NISP: pruning networks using neuron importance score propagation [C]. In: 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA. IEEE, 2018: 9194-9203
- [21] 亢洁, 刘港, 王勋, 夏宇, 郭国法, 刘文波. 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 J, Liu G, Wang Q, Xia Y, Guo G F, Liu W B. 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)
- [22] Huang L, Xu L J, Wang Y C, Peng Y Q, Zou Z Y, Huang P. Efficient detection method of Pig-Posture behavior based on multiple attention mechanism [J]. *Computational Intelligence and Neuroscience*, 2022, 2022: 1759542
- [23] 薛月菊, 朱勋沐, 郑婵, 毛亮, 杨阿庆, 涂淑琴, 黄宁, 杨晓帆, 陈鹏飞, 张

南峰. 基于改进 FasterR-CNN 识别深度视频图像哺乳母猪姿态[J]. 农业工程学报, 2018, 34(9): 189-196

Xue Y J, Zhu X M, Zheng C, Mao L, Yang A Q, Tu S Q, Huang N, Yang X F, Chen P F, Zhang N F. Lactating sow postures recognition from depth image of videos based on improved Faster R-CNN [J].

Transactions of the Chinese Society of Agricultural Engineering, 2018,

34(9): 189-196 (in Chinese)

[24] Ye H C, Zhang B, Chen T, Fan J Y, Wang B. Performance-aware approximation of global channel pruning for multitask CNNs [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(8): 10267-10284

责任编辑: 刘迎春



第一作者简介: 葛绍娟, 博士研究生/硕博连读, 现就读于中国农业大学水利与土木工程学院农业生物环境与能源工程专业。参与“山东省重点研发(乡村振兴科技创新提振行动计划)-绿色高效养猪全程信息数字化表征与获取技术研发”“青岛市科技惠民示范专项-生猪智能化环境和生物安全关键技术开发与应用示范”等项目, 参编专著《设施农业微酸性电解水绿色高效消毒理论与实践》《绿色低碳畜禽舍模块化装配式建筑图集》。



通讯作者简介: 郑炜超, 中国农业大学教授, 博士生导师, 国家蛋鸡产业技术体系鸡场规划与设施设备岗位科学家。主要从事畜禽养殖精准环控技术、智能养殖装备、生物安全工程防控技术与装备相关研究。现任中国农业工程学会畜牧工程分会秘书长、农业农村部畜牧水产养殖全程机械化专家指导组成员、动物环境与福利化养殖国际研究中心理事。近年来, 主持国家重点研发计划课题、国家自然科学基金等省部级以上项目 8 项, 获省部级(含社会力量设奖)科研奖励一等奖 5 项, 发表研究论文 80 余篇, 授权专利 26 件, 主编专著 2 部。