

基于 Jetson Nano + YOLO v5 的哺乳仔猪目标检测

丁奇安<sup>1</sup> 刘龙申<sup>2,3</sup> 陈佳<sup>1</sup> 太猛<sup>2</sup> 沈明霞<sup>2,3</sup>

(1. 南京农业大学工学院, 南京 210031; 2. 南京农业大学人工智能学院, 南京 210031;  
3. 江苏智慧牧业装备科技创新中心, 南京 210031)

**摘要:** 针对仔猪个体小、易被遮挡且仔猪目标检测方法不易在嵌入式端部署等问题,提出一种适用于 Jetson Nano 端部署的哺乳仔猪目标检测方法,在准确检测哺乳仔猪目标的同时,使模型实地部署更加灵活。使用哺乳仔猪图像建立数据集,数据量为 14 000 幅,按 8:1:1 划分训练集、测试集和验证集。利用深度学习网络提取哺乳仔猪特征,构建仔猪目标检测模型。融合推理网络中的 Conv、BN、Activate Function 层,合并相同维度张量,删除 Concat 层,实现网络结构量化,减少模型运行时的算力需求。将优化后模型迁移至 Jetson Nano,在嵌入式平台进行测试。实验结果表明,在嵌入式端,量化后 YOLO v5 中 4 种模型的单帧图像平均运行时间分别为 65、170、315、560 ms,检测准确率分别为 96.8%、97.0%、97.0% 和 96.6%,能够在 Jetson Nano 设备上对哺乳仔猪目标实现精准检测,为仔猪目标检测的边缘计算模式奠定基础。

**关键词:** 哺乳仔猪; 目标检测; YOLO v5; Jetson Nano; 边缘计算; 嵌入式端

中图分类号: TP391.41      文献标识码: A      文章编号: 1000-1298(2022)03-0277-08

OSID:



Object Detection of Suckling Piglets Based on Jetson Nano and YOLO v5

DING Qi'an<sup>1</sup> LIU Longshen<sup>2,3</sup> CHEN Jia<sup>1</sup> TAI Meng<sup>2</sup> SHEN Mingxia<sup>2,3</sup>

(1. College of Engineering, Nanjing Agricultural University, Nanjing 210031, China  
2. College of Artificial Intelligence, Nanjing Agricultural University, Nanjing 210031, China  
3. Jiangsu Smart Animal Husbandry Equipment Technology Innovation Center, Nanjing 210031, China)

**Abstract:** The deployment of piglet target detection model at the edge of the device is an important basis for fine management of piglets during lactation. Recognition of suckling piglets under complex environments is a difficult task, and deep learning methods are usually used to solve this problem. However, the object detection model of piglets based on deep learning often needs high computer force support, which is difficult to deploy in the field. To solve these problems, a object detection model of suckling piglets based on embedded terminal deployment was proposed, which made the deployment of piglet object detection system more flexible. A database was established by using images of suckling piglets with a data volume of 14000 pieces. The training set, test set, and validation set were divided by 8:1:1. The YOLO v5s, YOLO v5m, YOLO v5l, and YOLO v5x deep learning networks were trained to extract the characteristics of suckling piglets, and the corresponding piglets detection model was established to conduct object detection for suckling piglets. The Conv, BN, Activation Function layer, the same tensor and operation part of the network were fused, and the Concat layer was deleted to quantify the network structure and reduce the computational force demand of the model during operation. An embedded device Jetson Nano was used to infer the modified model to realize the deployment of piglet target detection model in the embedded terminal. The experimental results showed that the average running time of the optimized YOLO v5s, YOLO v5m, YOLO v5l, and YOLO v5x models were 65 ms, 170 ms, 315 ms and 560 ms, respectively, but the detection accuracy was dropped to 96.8%, 97.0%, 97.0% and 96.6%, respectively. The optimized YOLO v5s model can implement real-time detection of suckling piglets on embedded devices, which can lay a foundation for the edge computing model of piglets detection and provide technical support for precision breeding.

**Key words:** suckling piglets; object detection; YOLO v5; Jetson Nano; edge computing; embedded terminal

收稿日期: 2021-03-23    修回日期: 2021-04-20

基金项目: 江苏省科技计划项目 (BE2019382)

作者简介: 丁奇安 (1994—), 男, 博士生, 主要从事精准养殖和机器视觉研究, E-mail: dqa\_njau@163.com

通信作者: 沈明霞 (1964—), 女, 教授, 博士生导师, 主要从事机器视觉与信息农业研究, E-mail: mingxia@njau.edu.cn

0 引言

我国养猪业向规模化、集约化发展,生猪养殖产业总产值在整个畜牧业所占比重最高<sup>[1]</sup>。将人工智能技术引入生猪养殖管理,有利于实现精细化养殖,提高生产质量与动物福利<sup>[2]</sup>。哺乳期作为猪只生命周期的第一阶段,能够影响猪只后续生长状态,实现智能化仔猪目标检测能够为进一步探究猪只个体行为,例如躺卧<sup>[3]</sup>、爬跨<sup>[4]</sup>、攻击<sup>[5]</sup>、采食<sup>[6]</sup>、饮水<sup>[7]</sup>、运动<sup>[8]</sup>和个体跟踪<sup>[9]</sup>等任务奠定技术基础。

采用形态学<sup>[10-11]</sup>方式进行仔猪目标检测对设备要求低,但仔猪目标为非刚性,易产生尺度和形态变化,因此需要为目标个体添加人工标记来保障检测的精度,导致该方法不易在规模化猪场进行推广。而基于深度学习<sup>[12-15]</sup>的方法能够解决复杂环境下多尺度仔猪目标检测问题,逐渐成为该领域的研究热点。高云等<sup>[16]</sup>通过卷积神经网络构建仔猪识别模型 PigNet,实现群猪图像分割,准确识别猪只个体;王浩等<sup>[17]</sup>对 Faster R-CNN 结构进行改进,通过识别猪只目标建立猪只圈内位置识别算法;沈明霞等<sup>[18]</sup>利用 YOLO v3 网络,实现对初生仔猪目标的实时检测。高云等<sup>[19]</sup>提出基于双金字塔网络的 RGB-D 群猪图像分割方法。基于深层卷积神经网络的仔猪目标检测算法,无论是检测精度还是速度都较传统机器学习算法有所提升,但是对硬件算力的依赖,限制了其在实际养殖生产中的应用与推广。

边缘计算模式具有分布式、高效率、低延时和低成本等特点<sup>[20]</sup>。随着规模化猪场的不断发展,哺乳期仔猪数量也会持续增长,将数据处理任务分布式部署至养殖系统中靠近设备侧,减轻数据中心的计算压力、保障数据安全至关重要。采用边缘计算模式的难点之一是如何优化模型结构,使算法能够在低算力设备上运行。

本文采用 YOLO v5 网络训练哺乳期仔猪目标检测模型,Jetson Nano 开发板作为部署载体。其具有嵌入式端的 GPU 模块,能够更好地完成深度学习模型推理。将训练后的模型进行剪枝与量化,使得模型推理速度加快,形成能够在嵌入式端部署并精确检测目标的深度学习算法模型,实现哺乳期仔猪目标检测任务在边缘端的数据处理,使系统的部署更加灵活,满足不同规模的猪场需求,为构成适用于畜禽养殖领域的边缘计算模式奠定基础。

1 数据采集与预处理

实验数据采集于江苏省靖江市丰园生态农业园有限公司。选择两间面积同为 7 m×9 m 的母猪产

房,每间产房有 6 个 2.2 m×1.8 m 的分娩栏,每个分娩栏中配有 1 个分辨率为 2 048 像素×1 536 像素的海康威视(DS-2CD3135F-1 型)摄像头,对分娩栏内的母猪进行俯拍,拍摄高度为 3 m。视频采集时间为 2017 年 4 月 24 日—5 月 31 日。

对视频进行截图,截图速率为 1 f/s,截图完成后剔除数据集内异物遮挡严重以及相似度过高的图像,并保持夜间图像与白天图像数量一致,共计 14 000 幅图像。将图像缩放至 500 像素×375 像素以减少内存占用,采用开源软件 LabelImg 对图像进行标注,标注格式为 PASCAL VOC 数据集标准<sup>[21]</sup>,并按 8:1:1 将标注好的数据随机分配为训练集、测试集和验证集,图像中的仔猪数量范围为 0~15,包括 1 000 幅无仔猪存在的母猪图像。采用 Mosaic 数据增强方式,在数据输入网络前进行随机缩放、随机裁剪和随机排布,图像的处理效果如图 1 所示。



图 1 Mosaic 数据增强效果

Fig. 1 Data augmentation effect by Mosaic

2 仔猪目标检测模型优化与部署

2.1 YOLO v5 算法

受产房环境和哺乳期仔猪个体表征因素影响,哺乳期仔猪目标检测任务需要综合考虑检测精度与速度,而 one-stage 网络能够在检测过程中同时输出类别的锚框与概率,因此更加适合该任务场景。YOLO v3<sup>[14]</sup>能以 3 倍的推理速度取得与 SSD 相近的检测结果,YOLO v5 比 YOLO v3、YOLO v4<sup>[15]</sup>在检测速度与检测精度上有了进一步提升。所以本文基于 YOLO v5 算法进行优化,完成哺乳期仔猪目标检测模型的嵌入式端部署,YOLO 系列模型进行仔猪目标检测的主要过程如图 2 所示。

将一幅图像分成  $n \times n$  网格(grid cell),如果某



$\alpha$ ——权重函数  
 $I_{ou}$ ——预测框与实际框的交并比  
 $\nu$ ——宽高比度量函数  
 $w$ ——预测框的宽       $h$ ——预测框的高  
 $w^{gt}$ ——目标框的宽       $h^{gt}$ ——目标框的高

类间损失采用交叉熵损失函数 ( Binary cross entropy loss , BCEloss ), BCEloss 计算式为

$$l(x,y)=L=\sum(l_1,l_2\cdots,l_N)$$

(5)

其中  $l_N=-\omega[y_n\lg x_n+(1-y_n)\lg(1-x_n)]$

(6)

式中  $l(x,y)$ ——交叉熵损失函数

$l_N$ ——单批样本交叉熵损失值

$N$ ——一次训练的样本数

$x_n$ ——第  $n$  次输入的预测值

$y_n$ ——第  $n$  次输入的实际值

$\omega$ ——相关系数,取值为  $1/N$

object loss 采用 BCElogitsloss ( Binary cross entropy with logits loss ),即在 BCEloss 的基础上结合 sigmoid 函数,将式(6)变为

$$l_N=-\omega[y_n\lg S(x_n)+(1-y_n)\lg(1-S(x_n))]$$

(7)

其中  $S(x_n)=\frac{1}{1+e^{-x_n}}$

(8)

式中  $S(\cdot)$ ——sigmoid 函数

由于哺乳期仔猪为非刚性目标,易产生多尺度边框,因此采用自适应锚框计算方式<sup>[15]</sup>。

### 2.3 模型迁移

#### 2.3.1 模型优化

通过 CSP 结构来轻量化网络,但最终网络结构也较为复杂,模型在嵌入式端进行部署的效果并不理想,需要对网络结构进行优化,减少网络的复杂度,提升推理速度。将 Conv、BN 和 Activate Function 层进行融合<sup>[22]</sup>。

可以将 BN 层视为输入与输出通道数相同的  $1\times1$  卷积层。由于 BN 层位于 Conv 层之后,因此二者合并为新的卷积层。

Activate Function 层是在网络中的 BN 层后增加的非线性单元,维度尺寸需要与前一层相同,同理能够将 Activate Function 层与 Conv + BN 层进行融合。

Concat 层的主要作用是实现多输入的合并,将输入为相同张量和执行相同操作的部分进行融合即可代替 Concat 层,减少数据传输环节,实现对网络模型的量化和剪枝,具体操作示意图如图 5 所示。

图 5a 中,红色虚线框 1 表示将 Conv、BN 和 Activate Function 层进行融合,红色虚线框 2 表示将




图 5 网络优化操作示意图

Fig.5 Network optimization operation schematic

相同张量和操作进行融合,红色虚线框 3 表示将 Concat 操作删除,但对于卷积核不同的层无法进行相应的融合。图 5b 为优化后的网络结构,其中 CBR 表示 Conv、BN 和 Activate Function 层融合得到的新的卷积层。该优化方式是针对推理阶段进行数据处理推导过程的融合,在模型训练阶段不进行网络层的修改,因此能够保证训练过程的精度。

#### 2.3.2 模型部署

采用 Jetson Nano 进行模型迁移部署,Jetson Nano 测试图如图 6 所示。在深度学习主机上将训练好的 YOLO v5s、YOLO v5m、YOLO v5l、YOLO v5x 模型传入 Jetson Nano 开发板,在 Jetson Nano 开发板上优化并编译相应的 YOLO v5 模型文件,完成后进行模型转换,转换格式过程为 Pytorch 格式 (Pt) 一开




图 6 Jetson Nano 测试图

Fig.6 Experiment diagram on Jetson Nano

1. Jetson Nano 2. 外接显示器 3. 检测图像 4. 运行界面



放神经网络交换格式 ( Onnx )—TensorRT 格式 ( TRT ), 转换时模型计算精度为半精度计算, 采用 C ++ 程序接口实现 API 调用, 模型运行图像如图 6 所示。

2.4 模型评价指标

模型性能评价指标为单帧图像推理时间、精确率 ( Precision ) 和召回率 ( Recall ) 。

3 结果与分析

3.1 训练与嵌入式平台

模型训练平台使用 Intel i9 - 10900k 处理器; GPU 采用 NVIDIA GTX3090 型显卡, 显存为 24 GB; 操作系统为 Ubuntu18. 04; 在 Pytorch 深度学习框架上进行模型训练。


模型优化后的推理过程在 Jetson Nano 开发板上进行, GPU 为 128 - core Maxwell, CPU 为 Quad - core ARM A57 @ 1. 43 GHz, 内存为 4 GB、64 位 LPDDR4。相应配置系统为 ARM 版 Ubuntu16. 04 操作系统, 模型运行环境的配置为 JetPack4. 4、Python 3. 8、Pytorch 1. 6、Cuda 10. 1 和 TensorRT 7. 1。

3.2 训练参数设置

对各个网络模型的参数设置均保持一致, 其中迭代周期设置为 350, 批量大小设置为 16, 初始学习率设置为 0. 001, 初始冲量设置为 0. 98, 初始权重衰减系数为 0. 1, 每个迭代周期保存一次模型, 最终选取最优的模型。

3.3 模型训练结果与分析

训练 350 个迭代周期的边框损失值和目标损失



值曲线如图 7 所示。图 7 中, YOLO v5s 的损失值在迭代周期 0 ~ 70 之间下降了约 0. 008, 而在迭代周期 70 ~ 350 之间仅下降了 0. 002, YOLO v5m、YOLO v5l 和 YOLO v5x 的损失值曲线在约 70 个迭代周期之后每 50 个迭代周期平均下降 0. 002。由于本研究中的类别总数为 1, 所以类间损失值出现无限接近于 0 的情况, 此处不做说明。训练数据集的精确率、召回率和平均精度均值 ( mAP ) 曲线如图 8 所示。




图 7 边框损失值和目标损失值曲线  
Fig. 7 Results of bounding box loss and object loss

图 8 中, 平均精度均值 ( mAP ) 表示所有类别平均精度的平均值, 本文类别数为 1。mAP<sub>0.5</sub> 表示交并比阈值为 0. 5 时的 mAP, mAP<sub>0.5:0.95</sub> 表示交并比阈值在 [ 0. 5, 0. 95 ] 之间每隔 0. 05 取一次 mAP, 然后取的平均值。

由图 7 可知, 虽然模型的损失值曲线在 350 迭代周期内未完全拟合, 但是由损失值下降频率判断, 损失值曲线已经趋于拟合。结合图 8 可知, 模型精度随着训练次数增加不断上升, 但是网络模型的召回率在迭代周期 70 ~ 85 时开始下降。这




图 8 模型测试效果  
Fig. 8 Model tested effect diagrams

表明在约 70 个迭代周期之后,模型训练效果将不再随着迭代次数的增加而上升。因此,综合考虑  $mAP_{0.5}$  与召回率的变化情况,选取 350 个迭代周期权重模型中的最优权重模型,选取权重模型的测试性能如表 1 所示。

表 1 模型测试结果  
Tab.1 Results of model tested %

| 模型       | 精确率  | 召回率  |
|----------|------|------|
| YOLO v5s | 98.2 | 98.2 |
| YOLO v5m | 98.2 | 98.2 |
| YOLO v5l | 98.4 | 98.4 |
| YOLO v5x | 97.8 | 97.8 |

3.4 模型部署测试结果与分析

该优化方法虽然能够保留训练精度,但是由于模型在推理阶段的网络结构融合会使模型在加速时牺牲一部分检测精度。因此为验证模型转换后的有效性,将模型转换前后的效果进行对比,模型转换前后在 RTX3090 显卡与 Jetson Nano 上的测试效果如表 2 所示。

由表 2 可知,模型在转换后的精确率并没有太大的下降,但推理时间极大减少,YOLO v5s 与 YOLO v5m

表 2 模型测试效果对比

Tab.2 Comparison of model measuring effects

| 模型       | 处理平台        | 模型格式 | 处理速度/<br>(ms·f <sup>-1</sup> ) | 精确率/% | 召回率/% |
|----------|-------------|------|--------------------------------|-------|-------|
| YOLO v5s | RTX3090     | Pt   | 8                              | 98.2  | 98.2  |
| YOLO v5s | Jetson Nano | Pt   | 550                            | 98.2  | 98.2  |
| YOLO v5s | Jetson Nano | TRT  | 65                             | 96.8  | 96.4  |
| YOLO v5m | RTX3090     | Pt   | 15                             | 98.2  | 98.2  |
| YOLO v5m | Jetson Nano | Pt   | 1 600                          | 98.2  | 98.2  |
| YOLO v5m | Jetson Nano | TRT  | 170                            | 97.0  | 97.0  |
| YOLO v5l | RTX3090     | Pt   | 18                             | 98.4  | 98.4  |
| YOLO v5l | Jetson Nano | Pt   |                                |       |       |
| YOLO v5l | Jetson Nano | TRT  | 315                            | 97.0  | 97.0  |
| YOLO v5x | RTX3090     | Pt   | 21                             | 97.8  | 97.8  |
| YOLO v5x | Jetson Nano | Pt   |                                |       |       |
| YOLO v5x | Jetson Nano | TRT  | 560                            | 96.6  | 96.6  |

模型在 Jetson Nano 开发板上的运行时间分别缩短为原先运行时间的 65/550 和 17/160。同时,在未转换模型前,YOLO v5l 与 YOLO v5x 模型难以直接在 Jetson Nano 开发板上直接运行,模型转换后可以在开发板上运行,将主机端与 Jetson Nano 端的运行效果进行对比,结果如图 9 所示。



图 9 检测结果对比

Fig.9 Contrast of detection results

图 9 中每组图像的左侧图像是加速前的检测效果,右侧图像是加速后的检测效果。由图 9 可知,本研究构建的 YOLO v5 网络能够精准地检测出哺乳仔猪个体,优化后的模型在利用 TensorRT 加速时,能够在提升仔猪目标检测速度的同时保持有效检测精度。

进一步分析模型在 Jetson Nano 上的实际运行效果,为后续边缘计算模式下的模型部署提供理论依据。对 Jetson Nano 运行 YOLO v5 模型时的 GPU 利用率进行可视化,可视化结果如图 10 所示。

由图 10 可知,Jetson Nano 在运行不同网络深度和宽度的模型时,GPU 达到高负载的持续时间也是

不同的,网络结构越复杂的模型占用的 GPU 资源也就越多,随着模型复杂度的增加所需要的算力也是不断提升的。为了更好地在嵌入式端运行相应的模型,综合考虑模型复杂度与检测精度,优化后的 YOLO v5s 在 Jetson Nano 设备上的运行效果最好。图 11 为优化后的模型在 Jetson Nano 上检测不同环境条件下的仔猪目标结果。在光照充足的条件下,能够准确检测出仔猪聚集、阴影干扰情况下的仔猪目标;在无光照的条件下,仍然能够实现仔猪目标检测并应对异物遮挡问题,但是相较于光照条件下的检测效果,存在部分漏检情况,后续需要对该问题进行优化。






图 10 Jetson Nano 的 GPU 利用率  
Fig. 10 GPU utilization of Jetson Nano




图 11 优化后 YOLO v5s 检测效果  
Fig. 11 Results of detection with optimized YOLO v5s

4 结论

(1)构建哺乳期仔猪个体数据集,建立 YOLO v5 系列网络,训练哺乳期仔猪目标检测模型。在 RTX3090 的环境测试 YOLO v5s、YOLO v5m、YOLO v5l 和 YOLO v5x 4 种不同复杂度的网络模型,对比测试结果表明,YOLO v5s 模型拥有最快的处理速度,且 4 种模型的检测精确率均高于 97%。

(2)对基于 YOLO v5 的哺乳期目标检测模型进行量化与剪枝,实现模型在嵌入式设备 Jetson Nano 上的部署。在 Jetson Nano 上运行的 YOLO v5s 哺乳期仔猪目标检测模型的单帧图像处理速度仅需要 65 ms,YOLO v5m、YOLO v5l 和 YOLO

v5x 在测试集上的平均检测时间分别为 170、315、560 ms,检测精确率分别为 96.8%、97.0%、97.0% 和 96.6%。因此,综合考虑 YOLO v5s、YOLO v5m、YOLO v5l 和 YOLO v5x 模型在 Jetson Nano 上的运行速度和检测精度,优化后的 YOLO v5s 模型拥有更好的实际处理效果,能够实现哺乳期仔猪目标准确检测。

(3)规模化养殖使用边缘计算的基础是将算法模型部署至边缘设备。本研究提出一种基于 Jetson Nano 的哺乳期仔猪目标检测方法,能够为后续边缘计算在生猪养殖中的应用奠定基础,为智慧养殖提供技术支持,有助于加速生猪养殖的智能化进程。

## 参 考 文 献

- [1] 彭彦昆,杨清华,王文秀. 基于近红外光谱的猪肉水分在线检测与分级[J]. 农业机械学报,2018,49(3):347-353.  
PENG Yankun, YANG Qinghua, WANG Wenxiu. Online detection and classification of pork moisture based on near-infrared spectra[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(3): 347-353. (in Chinese)
- [2] 张海峰. 生猪“保险+期货”模式的市场功能与社会意义[J]. 中国猪业, 2020, 15(6): 20-22, 32.  
ZHANG Haifeng. Market function and social significance of “insurance + futures” mode of live pigs[J]. China Swine Industry, 2020, 15(6): 20-22, 32. (in Chinese)
- [3] NASIRAHMADI A, HENSEL O, EDWARDS S A, et al. A new approach for categorizing pig lying behaviour based on a delaunay triangulation method[J]. Animal, 2017, 11(1): 131-139.
- [4] NASIRAHMADI A, HENSEL O, EDWARDS S A, et al. Automatic detection of mounting behaviours among pigs using image analysis[J]. Computers and Electronics in Agriculture, 2016, 124: 295-302.
- [5] VIAZZI S, ISMAYILOVA G, OCZAK M, et al. Image feature extraction for classification of aggressive interactions among pigs[J]. Computers and Electronics in Agriculture, 2014, 104: 57-62.
- [6] YANG Q, XIAO D, LIN S. Feeding behavior recognition for group-housed pigs with the Faster R-CNN[J]. Computers and Electronics in Agriculture, 2018, 155: 453-460.
- [7] CHEN C, ZHU W, STEIBEL J, et al. Classification of drinking and drinker-playing in pigs by a video-based deep learning method[J]. Biosystems Engineering, 2020, 196: 1-14.
- [8] KASHIHA M, BAHR C, OTT S, et al. Automatic monitoring of pig locomotion using image analysis[J]. Livestock Science, 2014, 159: 141-148.
- [9] MATTHEWS S G, MILLER A L, PLÖTZ T, et al. Automated tracking to measure behavioural changes in pigs for health and welfare monitoring[J]. Scientific Reports, 2017, 7(1): 1-12.
- [10] NAVARRO-JOVER J M, ALCANIZ-RAY M A, GOMEZ V, et al. An automatic colour-based computer vision algorithm for tracking the position of piglets[J]. Spanish Journal of Agricultural Research, 2009, 7(3): 535-549.
- [11] KASHIHA M, BAHR C. Automatic identification of marked pigs in a pen using image pattern recognition[J]. Computers & Electronics in Agriculture, 2013, 93: 111-120.
- [12] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(6): 1137-1149.
- [13] 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: 2980-2988.
- [14] REDMON J, FARHADI A. YOLO v3: an incremental improvement[J]. arXiv preprint arXiv:1804.02767.
- [15] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLO v4: optimal speed and accuracy of object detection[J]. arXiv preprint arXiv:2004.10934.
- [16] 高云,郭继亮,黎焯,等. 基于深度学习的群猪图像实例分割方法[J]. 农业机械学报, 2019, 50(4): 179-187.  
GAO Yun, GUO Jiliang, LI Xuan, et al. Instance-level segmentation method for group pig images based on deep learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(4): 179-187. (in Chinese)
- [17] 王浩,曾雅琼,裴宏亮,等. 改进 Faster R-CNN 的群养猪只圈内位置识别与应用[J]. 农业工程学报, 2020, 36(21): 201-209.  
WANG Hao, ZENG Yaqiong, PEI Hongliang, et al. Recognition and application of pigs' position in group pens based on improved Faster R-CNN[J]. Transactions of the CSAE, 2020, 36(21): 201-209. (in Chinese)
- [18] 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)
- [19] 高云,廖慧敏,黎焯,等. 基于双金字塔网络的 RGB-D 群猪图像分割方法[J]. 农业机械学报, 2020, 51(7): 36-43.  
GAO Yun, LIAO Huimin, LI Xuan, et al. RGB-D segmentation method for group piglets images based on double-pyramid network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(7): 36-43. (in Chinese)
- [20] DENG S, ZHAO H, FANG W, et al. Edge intelligence: the confluence of edge computing and artificial intelligence[J]. IEEE Internet of Things Journal, 2020, 7(8): 7457-7469.
- [21] EVERINGHAM M, GOOL L V, WILLIAMS C K I, et al. The pascal visual object classes (VOC) challenge[J]. International Journal of Computer Vision, 2010, 88(2): 303-338.
- [22] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C] // International Conference on Machine Learning. PMLR, 2015: 448-456.