

# 常态养殖下妊娠母猪体质量智能测定模型

肖德琴<sup>1</sup>, 刘俊彬<sup>1</sup>, 刘又夫<sup>1</sup>, 黄一桂<sup>1</sup>, 谭祖杰<sup>1</sup>, 熊本海<sup>2</sup>

(1. 华南农业大学 农业农村部华南热带智慧农业技术重点实验室, 广州 510642;

2. 中国农业科学院北京畜牧兽医研究所, 北京 100193)

**摘要:** 针对常态养殖下视频图像中常见的遮挡问题, 该研究借鉴深度学习技术中的实例分割和关键点检测算法, 提出了基于深度学习的妊娠母猪体质量智能测定模型 (Intelligent Mass Measurement Model for Gestating Sows, IMMM-GS)。该模型包括基于 Mask R-CNN 的猪只实例分割算法、基于 Keypoint R-CNN 的猪只关键点检测算法和基于改进的 ResNet 网络的猪只质量估测算法 3 个主要算法, 用以处理常态环境下围栏、食槽、排泄物等影响猪体质量估测的典型遮挡问题。试验使用 48 头妊娠母猪 6 个月的常态视频图像和猪体质量数据进行数据集构建和试验分析, 模型在测试集上的均方根误差为 3.01 kg, 相较于以 ConvNeXt 和 ResNet 为骨干网络的模型分别降低 2.14 和 7.86 kg, 模型精度得到较大提升。此外, 该模型还对 10 头妊娠母猪进行了 3 个月的猪体质量跟踪监测验证, 在图像大小为  $2\ 688 \times 1\ 520$  的情况下, 每幅图像的平均估算速度为 0.684 s, 估测质量与真实质量的均方根误差平均值为 3.24 kg, 计算速度与精度基本满足实时运算需求。IMMM-GS 模型能够利用常态视频长时间实时评估母猪妊娠期的质量增长规律、妊娠母猪发育状况、估测预产期和产仔数等繁殖性能提供了数据支持, 具有广阔的应用前景。

**关键词:** 计算机视觉; 深度学习; 妊娠母猪; 质量测定; 卷积神经网络

doi: 10.11975/j.issn.1002-6819.2022.z.018

中图分类号: S818; TP391

文献标志码: A

文章编号: 1002-6819(2022)-Supp.-0161-09

肖德琴, 刘俊彬, 刘又夫, 等. 常态养殖下妊娠母猪体质量智能测定模型[J]. 农业工程学报, 2022, 38(增刊): 161-169.

doi: 10.11975/j.issn.1002-6819.2022.z.018 <http://www.tcsae.org>

Xiao Deqin, Liu Junbin, Liu Youfu, et al. Intelligent mass measurement model for gestating sows under normality breeding[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2022, 38(Supp.): 161-169. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.2022.z.018 <http://www.tcsae.org>

## 0 引言

猪体质量是衡量猪生长发育状况和评估其健康状况的一项重要指标<sup>[1]</sup>, 其体质量的变化决定了生猪养殖的生产管理策略。为了提高饲养效率, 商业化养殖场需要根据猪体质量增长曲线制定合适的饲养方案。母猪体况过瘦会导致断奶至配种间隔延长并降低产仔数; 母猪体况过肥会造成因肢蹄病淘汰的母猪比例升高, 同时难产和死胎的比例也会升高。因此, 有效监测猪体质量可以帮助饲养管理员制定更合理的饲养决策<sup>[2]</sup>。

当前生猪养殖场主要靠养殖场工作人员将猪牵引到体重秤上进行称量, 该方法不仅耗时费力且会导致生猪应激和死亡率增加<sup>[3]</sup>。通常情况下, 养殖场工作人员需要花费 3~5 min 称量 1 头猪。此外, 秤和猪的频繁交互可能会造成机器损坏从而得到错误的结果<sup>[4]</sup>。

利用计算机视觉技术进行非接触式动物体质量测定成为近年研究应用热点, 分别在鸡<sup>[5-6]</sup>、猪<sup>[7-9]</sup>、牛<sup>[10-13]</sup>等主要畜禽开展了广泛的探索。该自动化方法能够减少生猪和养殖场工作人员的压力, 帮助养殖场连续实时监测猪体质量, 及时调整养殖策略。例如李卓等<sup>[9]</sup>利用摄像机

获取猪只表面积、胸围、体长、体高等与质量相关的参数, 基于幂回归建立了一个非线性猪体质量模型; Jun 等<sup>[7]</sup>通过构建特征工程提取俯视二维图片中猪只的身体面积、头部位置、身体扭曲程度等特征, 最后通过全连接神经网络测定猪体质量; Shahinfar 等<sup>[11]</sup>试验发现牛体质量估测模型利用支持向量机结合顺序最小优化方法的效果最佳; Le Cozler 等<sup>[12]</sup>利用 3D 摄像头采集的三维深度信息提取牛的体积和表面积等形态学特征, 构建回归方程以测定牛体质量的方法。以上基于机器学习方法的研究在动物体质量估测上取得了一定成果, 但基于机器学习的算法都需要针对不同数据集进行特征工程构建, 模型构建过程较为繁琐且很难迁移使用。

与上述传统的机器学习方法需要构建特征工程相比, 利用深度学习自动学习提取特征的方法在构建动物体质量测定模型上取得了更好效果<sup>[13-14]</sup>。例如 Dan 等<sup>[15]</sup>构建的卷积神经网络模型来测定单头猪体质量的模型取得了较大进步, 平均百分比误差为 7%, 决定系数  $R^2$  为 95%; Cang 等<sup>[16]</sup>进一步在 Faster R-CNN 上新增了回归分支, 将猪只目标检测和体质量回归网络整合到端到端的网络中, 提高了模型的泛化性能; Zhang 等<sup>[17]</sup>将猪控制在限位栏中, 利用多输出回归卷积神经网络来估测猪体质量, 使用修改后的 Xception 作为特征提取网络, 估重模型的决定系数  $R^2$  提高到 0.988; Meckbach 等<sup>[18]</sup>基于 EfficientNet 构建, 在测试集上的平均百分比误差为 4%; He 等<sup>[19]</sup>在 BotNet 网络的基础上构建的猪体质量估测模

收稿日期: 2022-10-02 修订日期: 2022-11-21

基金项目: 国家重点研发计划 (2021YFD200802); 生猪健康识别、养殖环境控制设备技术研发与规模化示范项目 (2018A020101)

作者简介: 肖德琴, 博士, 教授, 博士生导师, 研究方向为物联网、农业视频图像处理。Email: deqinx@scau.edu.cn

型,在测试集上的平均绝对误差小于 6.366 kg。上述研究多是将猪只赶至特定区域中对猪只进行图像获取和体质量测定,样本数量有限。然而,在生猪常态养殖舍中,围栏、食槽、猪只排泄物等不同尺度的无关物体必然会影响到测定模型的效果,当前研究都未对这些常态养殖模式下必然出现的上述无关物体带来的遮挡问题进行讨论与解决。因此,上述所有猪体质量估测方案在常态养殖模式下进行长时间猪体质量测定应用都还存在不足。

为了实现长时间的母猪体质量测定和减少遮挡对猪体质量测定的影响,本文结合实例分割和关键点检测算法,提出一种基于深度学习的妊娠母猪体质量智能测定模型(Intelligent Mass Measurement Model for Gestating Sows, IMMM-GS),通过实例分割和关键点监测,在处理遮挡问题的同时实现利用低成本监控设备对母猪妊娠期长时间体质量监测,为常态养殖下猪体质量测定提供解决方案。

## 1 数据集构建

### 1.1 试验部署与数据采集

本文试验于 2022 年 4 月至 10 月在广东省广州市从化区达南猪场进行。为采集妊娠母猪的视频图像数据,在母猪限位栏上方布设了团队前期研发的轨道式巡检机器人,机器人上搭载了海康威视 TB-1217A-3/PA 彩色摄像头,视频帧率为 25 帧/s,分辨率为 2 688×1 520。摄像头与地面平行,距离地面约 1.9 m,摄像头与一台微型计算机(型号为 Dell OptiPlex 3080 Micro,操作系统为 Windows 11 Pro, GPU 为 Intel Core i5-10500T,内存为 8 GB,存储空间大小为 256 GB)相连接,以确保视频图像数据及时上传云端。设备与试验场景如图 1 所示。

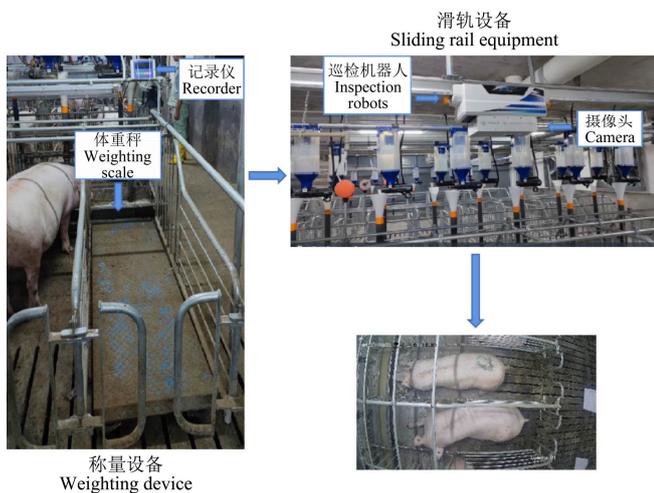


图 1 试验部署与数据采集

Fig.1 Experimental deployment and data collection process

本研究所使用彩色摄像头采用超过 200 万像素的普通摄像头即可满足,因为在现行不超过 2 m 安装高度下,针对猪身长宽看来,200 万像素摄像头在猪身上每个像素点实际对应的猪只表面积已经不超过 1 mm<sup>2</sup>,实际落在猪体身上的像素点已经超过 100 万个,包含了描述猪只形态的足够信息,增加摄像头像素已经对算法精度的影响甚微,所以普通视频即可满足本研究数据采集需要<sup>[20]</sup>。

试验期内,共采集了 48 头 150~200 kg 之间的妊娠期母猪视频图像数据及体质量数据。选择每天 08:00 至 10:00 和 14:00 至 16:00 阶段的采食视频图像数据作为基础数据集,此时母猪处于进食阶段,站立姿态居多,能够更好地获取完整的猪只个体。

试验时,每隔 5 d 对试验母猪体质量进行 1 次称量,获得上述母猪从妊娠前期到妊娠后期的体质量数据。针对深度学习建模的需要,本研究构建了实例分割数据集、关键点检测数据集和体质量数据集三个子集。所有数据集均以 7:2:1 的比例随机划分成训练集、测试集与验证集。

### 1.2 猪只实例分割数据集

为减少猪栏等背景环境对猪体质量的影响,本文引入实例分割技术将猪只从背景中提取出来。试验中构建了一个包含 7 800 张图片的猪只实例分割数据集,用于实例分割网络的训练、验证与测试,数据集采用 Labelme 数据标注工具进行标注,并保存为 COCO 数据集格式<sup>[21]</sup>。为进一步提高分割模型的鲁棒性和稳定性,本文在标注的基础上对数据集进行了数据增强,将猪只个体轮廓的外接矩形裁剪出来生成新图像,并对其标签进行坐标转换处理形成新图像标签,最后将新图像及其标签添加到数据集中。除了上述数据外,本文在数据集中还添加了从互联网中下载和其他试验猪场的母猪图像,以提高数据多样性,增强模型泛化能力。

### 1.3 猪只关键点检测数据集

本研究在实例分割数据集的基础上标注关键点以构造关键点检测数据集,用于猪只关键点检测模型的训练、测试和验证。采用关键点检测的目的是判断图片中的猪只身体是否完整,在实际生产中,受拍摄视角和猪只位置等因素的影响,摄像头画面中的猪只身体可能会被围栏、食槽等其他物体所遮挡,这些“被遮挡”的猪只图像不能用于体质量估测模型的训练,否则会影响测定的精度。为了解决这些常态养殖下必然出现的常见遮挡问题,借鉴人体姿态识别中的关键点检测技术,选择了猪只头部、颈部、背部、臀部、尾部 5 个关键点,如图 2 所示。通过对关键点的检测来判断猪只身体的完整性,以剔除不适合用于体质量测定的图像。



图 2 猪只关键点

Fig.2 Keypoints of pig

### 1.4 猪体质量数据集

本文通过关键点检测算法剔除实例分割数据集中关键点缺失的图片,构建了一个包含 48 头母猪妊娠阶段 6 882 张图片的猪体质量数据集,用于猪体质量估测算法的训练、验证与测试。

### 2 妊娠母猪体质量智能测定模型构建

本文构建了基于深度学习的妊娠母猪体质量估测模型 IMMM-GS，包括基于 Mask R-CNN 网络的猪只实例分割算法、基于 Keypoint R-CNN 网络的猪只关键点监测算法、基于改进的 ResNet 网络的猪体质量估测算法 3 个子模块，模型流程如图 3 所示。

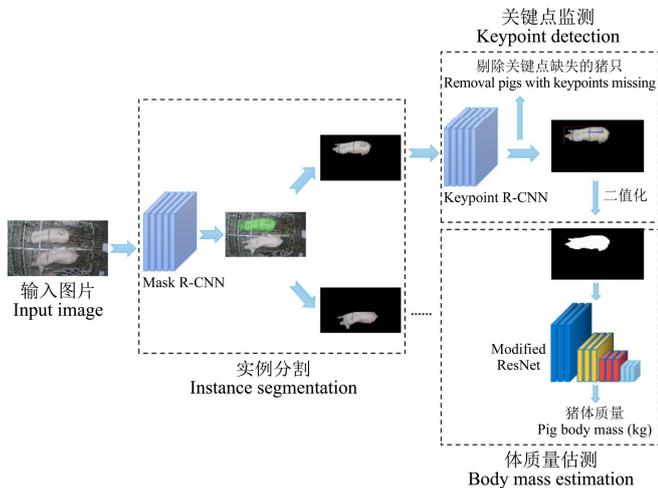


图 3 妊娠母猪体质量智能测定模型流程图

Fig.3 Flow chart of Intelligent Mass Measurement Model for Gestating Sows (IMMM-GS) model

图 3 显示，IMMM-GS 模型首先使用猪只实例分割算法提取图片中猪只个体的掩模，根据掩模去除无关物体；然后通过猪只关键点检测算法检测猪只身上的关键点，并根据关键点的完整情况剔除被遮挡的猪只图像；最后对这些符合要求的图片进行二值化，再将二值化结果输入到猪体质量测定算法中进行特征提取和计算。

#### 2.1 基于 Mask R-CNN 的猪只实例分割算法

本文的猪只实例分割算法主要基于 Mask R-CNN 网络进行构建。Mask R-CNN 网络由用于目标检测和分类的 Faster R-CNN 和用于语义分割的全连接网络两部分组成。与传统的分割方法相比，Mask R-CNN 算法的优势在于它

可以同时进行检测、分类和图像分割<sup>[22]</sup>。

虽然 Mask R-CNN 算法对于比较显著的大型目标具有良好的分割效果，但应用在本试验中我们发现养殖环境中存在的围栏、食槽、排泄物等不同尺度的无关物体对猪只的分割存在较大干扰。同时，实例分割算法需要在检测出猪只个体同时，对图像上的像素进行分类，这要求算法必须具有较强的处理多尺度信息的能力。

IMMM-GS 模型结合近年来卷积神经网络的最新网络结构进行改进，以提高网络对多尺度信息的表达能力，改进网络结构如图 4 所示。由图 4 可知，改进的网络结构，其主要改进措施包括如下 5 个方面：

1) 引入多分支卷积模块。为解决 ResNet<sup>[23]</sup>对细粒度特征表示能力较差的不足，IMMM-GS 模型借鉴 Res2Net<sup>[24]</sup>多分支卷积的思想，使用 1 组较小的滤波器组替换 3×3 滤波器，如图 5 所示，新的 3×3 滤波器组以分层类似残差样式的连接以增加网络的感受野和提高多尺度表示能力。具体操作办法是：经过 1×1 卷积后，输入特征图被分成多组，一组滤波器首先从一组输入特征图中提取信息；再将上一组的输出特征图与另一组输入特征图一起发送到下一组滤波器；重复此过程几次，直到处理完所有输入特征图；最后将所有组的特征图连接并送入 1×1 滤波器，以完全融合信息。沿着输入特征图到输出特征图任何可能路径，当通过 3×3 滤波器时，等效感受野都会增加，由于组合效应，从而得到许多等效特征尺度信息。

2) 引入 depthwise 卷积。虽然 Res2Net 残差结构的参数量没有明显的增加，但其多分支结构仍会破坏网络的并行性，降低网络计算速度。为了避免模型的速度过慢，本文仅将 ResNet 网络卷积模块 stage4 部分的瓶颈层替换为 Res2Net 的多分支卷积形式。对于其他 stage，借鉴 ConvNeXt<sup>[25]</sup>中验证的优化思路进行改进，使用了文献 [26]提出的 ResNeXt 中 depthwise 卷积，在计算量和准确性之间做到了更好的平衡。

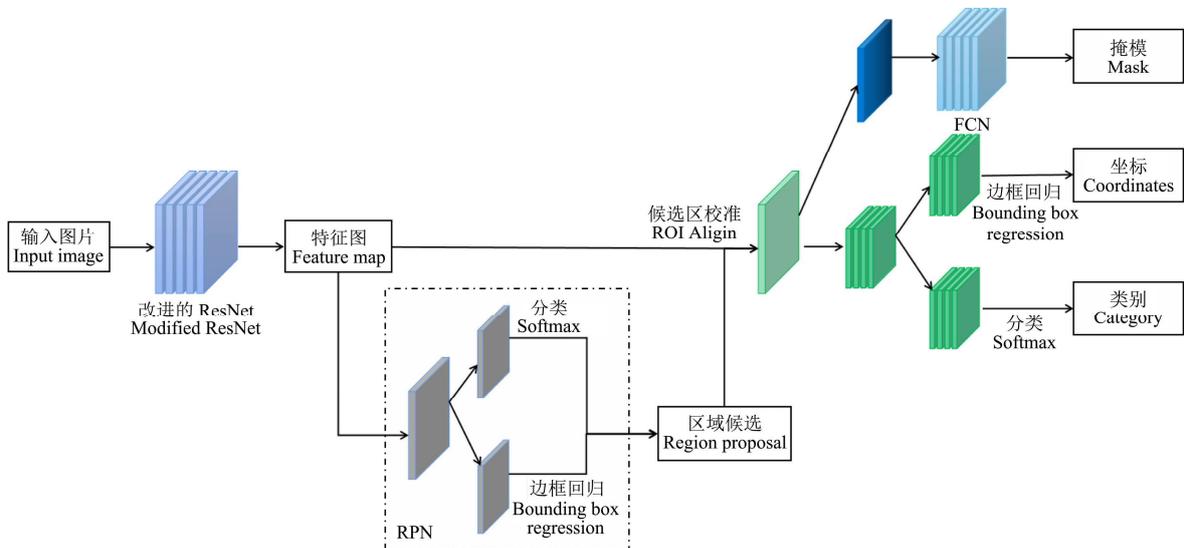


图 4 Mask R-CNN 算法结构图

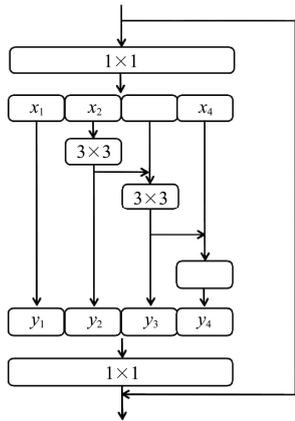
Fig.4 Structure of Mask R-CNN algorithm

3) 逆瓶颈层的应用。本文使用了文献[27]中提出的 MobileNetV2 的逆瓶颈层结构, 采用“小维度-大维度-小维度”形式, 确保特征图的信息在不同维度特征空间之间转换时可避免压缩维度带来的信息损失, 防止了降采样过程中猪只身体上的细节特征信息丢失。

4) 改进标准化层和激活层。本文通过减少了归一化层和激活层的数量、层标准化取代批标准化和 GELU 代替 ReLU 三大策略来减少了训练过程中梯度的震荡。

5) 使用  $7 \times 7$  卷积取代  $3 \times 3$  卷积。本研究借鉴文献 [28] 中 Swin Transformer 增大感受野的理念, 使用  $7 \times 7$  卷积核替代 ResNet 中的  $3 \times 3$  卷积核的办法使模型获得更大的感受野。

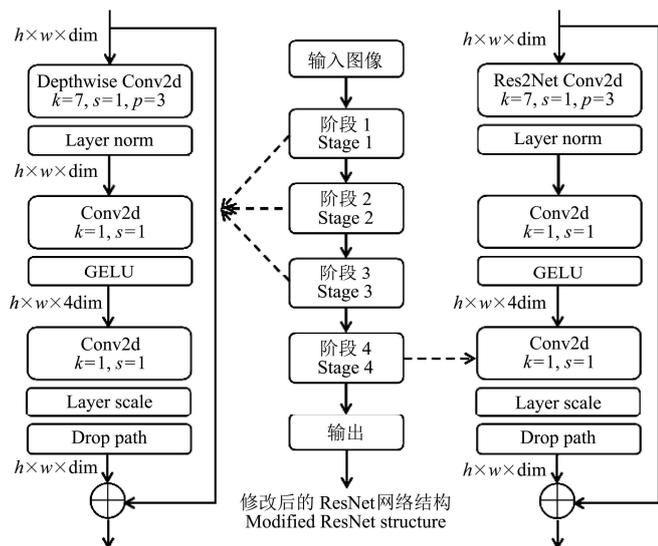
经过上述 5 方面改进的 ResNet 结构如图 6 所示。



注:  $x_1 \sim x_4$  表示分组后的输入特征图,  $y_1 \sim y_4$  表示通过滤波器组进行特征提取后得到的特征图。

Note:  $x_1 \sim x_4$  denote the input feature maps after grouping,  $y_1 \sim y_4$  denote the feature map after feature extraction by filters.

图 5 Res2Net 残差结构图  
Fig.5 Residual structure of Res2Net



注:  $h$  和  $w$  表示输入特征的长和宽,  $dim$  为特征通道数,  $k$  表示卷积核的大小,  $s$  表示卷积核的步长,  $p$  表示卷积核的填充。修改后的 ResNet 网络的前 3 个 stage 不引入 Res2Net 残差结构, 只在第 4 个 stage 引入。

Note:  $h$  and  $w$  are the length and width of the input features,  $dim$  is the number of feature channels,  $k$  means the kernel size,  $s$  means the stride of the kernel and the  $p$  means the padding of kernel. The modified ResNet network does not introduce the Res2Net residual structure in the first 3 stages, but only in the 4th stage.

图 6 修改后的 ResNet 网络结构  
Fig.6 Structure of modified ResNet network

### 2.2 基于 Keypoint R-CNN 的猪只关键部位检测算法

本文猪只关键点检测算法基于 Keypoint R-CNN 网络构建。Keypoint R-CNN 网络是在 Mask R-CNN 网络的基础上扩展得到, 将 Mask R-CNN 网络的掩模分支替换为关键点检测分支。关键点检测包括检测猪只和定位其关键点, 网络对检测到的物体上的关键点进行单独编码, 最终输出每个关键点的类型和位置。与实例分割算法类似, 关键点检测算法也需要在检测出猪只个体同时对图像上的像素进行分类, 需要特征提取网络具有较强的处理多尺度信息的能力, 因此本文将 Keypoint R-CNN 算法的特征提取网络替换为 2.1 节中改进后的 ResNet, 以减少算法的训练时间和训练过程中的震荡。

猪只关键点检测算法使用 1.3 节描述的猪只关键点数据集进行训练, 将 2.1 节描述的 Mask R-CNN 算法模型迁移学习作为 Keypoint R-CNN 算法的预训练模型。

### 2.3 基于改进 ResNet 的猪体质量测定算法

猪体质量测定算法使用 2.1 节中改进后的 ResNet 进行构建, 为了使网络最终回归出一个猪体质量值, 本算法修改了网络的全连接层, 新算法结构如图 7 所示。猪体质量测定算法将处理后的猪只图片作为输入, 将其实际体质量作为目标值, 使得网络能够学习到体质量测定所需要的特征, 并将这些在关键点检测数据集上训练得到的 Keypoint R-CNN 的特征提取网络的权重模型迁移学习为体质量测定算法的预训练模型。

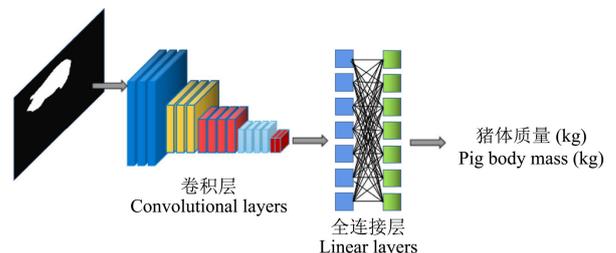


图 7 猪体质量测定算法结构图  
Fig.7 Structure map of pig mass measurement algorithm

### 3 猪体质量测定模型试验及分析

为了验证 IMM-GS 模型的性能, 本团队基于 Python 和 OpenCV 等环境实现了上述算法, 并在 Ubuntu 操作系统环境下进行了模型训练及测试。具体实现主要基于以下框架和软件包: Python 3.9, Pytorch 框架 (版本 1.9), MMPose 框架 (版本 0.280), MMDetection 框架 (版本 2.250), CUDA (版本 10.0), cuDNN (版本 8.0), OpenCV (版本 3.4)。模型训练及测试所用到的软硬件环境如下: 操作系统为 Ubuntu 18.04.6 LTS, CPU 为 Intel Core I7-9700 3.0 GHZ, GPU 为 NVIDIA A30, 显存 24 GB, 内存 16 GB, 硬盘为 256 GB 固态硬盘+8T 机械硬盘。

为了评估 IMM-GS 算法模型的性能, 本研究同样采用机器学习领域惯常使用的平均精度 (Average Precision, AP) 作为评价指标进行评估。AP 主要又由精确率 (Precision Rate, PR) 和召回率 RR 来表征, 与交并比 IOU(Intersection over Union)数量有关, AP、PR 和 RR 共 3 个参量的具体计算式如下:

$$AP = \sum_{k=0}^{k=n-1} [\text{Recalls}(k) - \text{Recalls}(k+1)] \cdot \text{Precision}(k) \quad (1)$$

$$PR = \frac{TP}{TP + FP} \quad (2)$$

$$RR = \frac{TP}{TP + FN} \quad (3)$$

式中 TP 表示被正确分类的正例样本量；TN 表示被正确分类的负例样本量；FP 表示被错误分类为正例的负例样本量；FN 表示被错误分类为负例的正例样本量； $n$  表示 IOU 阈值的数目；Recalls( $k$ )和 Precision( $k$ )分别表示取第  $k$  个 IOU 阈值时的召回率和精确率。

以下将重点分析实例分割算法、关键点检测算法、体质量测定算法和测定模型 4 个关键子算法性能。

### 3.1 猪只实例分割算法性能分析

本实例分割算法使用 1.2 节描述的猪只实例分割数据集进行训练，并在 COCO 数据集上训练过的预训练模型进行初始化，算法训练参数设置如表 1 所示。

表 1 实例分割算法训练参数

Table 1 Parameters of instance segmentation algorithm

参数 Parameters	数值 Value
初始学习率 Initial learning rate	0.002
学习率衰减率 Learning rate decay rate	0.1
权重衰减率 Weight decay rate	0.0005
批处理大小 Batch size	4
迭代次数 Iteration	9 000

为了验证算法改进效果，本试验使用 ResNet、

表 2 实例分割算法在不同特征提取网络下的性能

Table 2 Results of different feature extraction networks in instances segmentation algorithm

骨干网络 BackBone network	训练集 Training set/%		验证集 Validation set/%		测试集 Testing set/%		平均预测速度 Average speed/ (s·帧 <sup>-1</sup> )	骨干网络的参数量 BackBone Params/M
	检测框的平均精度 Average precision of bounding box	掩模的平均精度 Average precision of mask	检测框的平均精度 Average precision of bounding box	掩模的平均精度 Average precision of mask	检测框的平均精度 Average precision of bounding box	掩模的平均精度 Average precision of mask		
ResNet	97.22	90.59	93.93	88.39	92.84	87.85	0.392	25.56
ConvNeXt	98.85	91.60	94.10	89.88	93.03	88.98	0.443	28.59
ResNet (Improved)	99.81	92.30	94.63	91.65	93.65	91.04	0.662	28.72

### 3.2 猪只关键点检测算法性能分析

在算法评估方法上，关键点检测算法和实例分割算法一样采用 AP 来评估，与实例分割算法利用 IOU 评估不同，关键点检测算法采用物体关键点相似性 OKS (Object Keypoint Similarity) 来定义真实对象和预测对象之间的匹配程度。与 IOU 类似，预测对象和真实对象只有匹配程度超过一定阈值时才会认为预测正确，OKS 的计算公式为

$$OKS = \exp\left(-\frac{d_i^2}{2s^2l_i^2}\right) \quad (4)$$

式中  $d_i$  表示预测关键点和真实关键点之间的欧几里得距离，pixel； $s$  表示关键点所在目标在图像上所占的面积，pixel<sup>2</sup>； $l_i$  表示第  $i$  个关键点的归一化因子。

关键点监测算法使用不同特征提取网络在训练集和验证集上的损失函数曲线性能情况如图 9 所示，试验结果如表 3 所示。结果显示经过改进的 ResNet 网络作为骨干网络时算法表现最优，在测试集上的关键点检测精度

ConvNeXt 和修改后的 ResNet 分别作为实例分割算法的特征提取网络分别进行训练和验证，并进行对比分析，试验如图 8 所示，具体结果如表 2 所示，试验显示经过改进的 ResNet 网络相比其他 2 个网络 loss 收敛速度更快且收敛后的训练集损失值和验证集损失值之间相差较小，这表明模型得到一个较好的拟合。

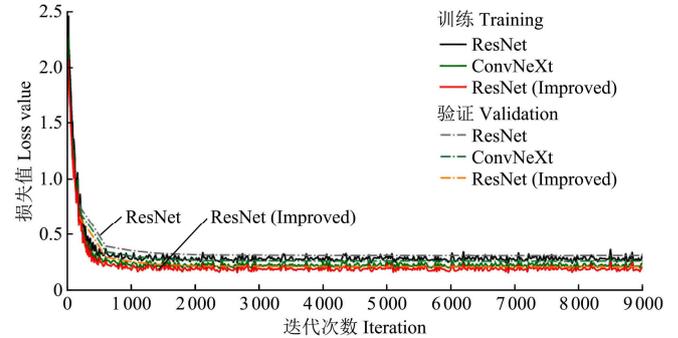


图 8 实例分割算法在不同特征提取网络上的损失函数曲线  
Fig.8 Loss function curves of instance segmentation algorithms for different feature extraction networks

此外，试验还对本文在多分支卷积模块、大卷积核、逆瓶颈层等核心改进点在法处理多尺度信息和特征提取的性能进行了对比分析。修改后的 ResNet 网络的参数略大于原 ResNet 网络 ConvNeXt 网络，分别增大了 3.16 和 0.13 M，运算速度下降 0.2~0.4 s/帧，但是在测试集上的分割精度为 91.04%，比以 ConvNeXt 和 Res2Net 为骨干网络的实例分割算法高出 2.06 和 3.19 个百分点。

为 90.89%，比以 ConvNeXt 和 Res2Net 为骨干网络的关键点检测算法高出 1.05 和 4.08 个百分点。

### 3.3 猪体质量测定算法性能分析

猪体质量测定算法使用 1.4 节描述的猪体质量数据集进行训练，训练参数设置如表 4 所示。

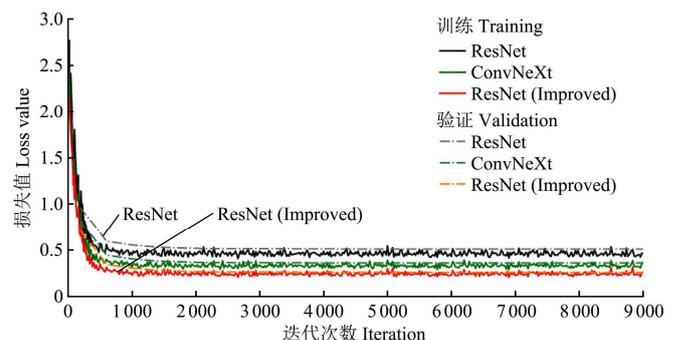


图 9 关键点检测算法在不同特征网络上的损失函数曲线  
Fig.9 Loss function curves of keypoint detection algorithms for different feature extraction networks

表3 不同特征提取网络的关键点检测算法结果

Table 3 Results of different feature extraction networks in keypoint detection algorithm

骨干网络 BackBone network	训练集 Training set/%		验证集 Validation set/%		测试集 Testing set/%		平均预测速度 Average speed/ (s·帧 <sup>-1</sup> )
	检测框的平均精度 Average precision of bounding box	关键点的平均精度 Average precision of keypoint	检测框的平均精度 Average precision of bounding box	关键点的平均精度 Average precision of keypoint	检测框的平均精度 Average precision of bounding box	关键点的平均精度 Average precision of keypoint	
ResNet	94.45	87.94	93.50	85.59	89.75	85.51	0.262
ConvNeXt	97.86	89.59	94.52	89.62	92.53	88.54	0.356
ResNet (Improved)	98.81	91.89	96.03	90.89	94.38	89.59	0.542

表4 猪体质量测定算法训练参数

Table 4 Parameters of pig mass measurement algorithm

参数 Parameters	数值 Values
初始学习率 Initial learning rate	0.0025
学习率衰减率 Learning rate decay rate	0.1
权重衰减率 Weight decay rate	0.0005
批处理大小 Batch size	1
迭代次数 Epoch	800

为了评估猪体质量测定算法的性能,参考中国农大张建龙等的评估方法<sup>[4]</sup>,使用均方根误差(Root Mean Square Error, RMSE, 简记为  $E_{rms}$ )和平均绝对百分比误差(Mean Absolute Percentage Error, MAPE, 简记为  $E_{map}$ )作为评价指标。 $E_{rms}$ 和 $E_{map}$ 均为回归模型常用的评估指标,具体计算公式如下:

$$E_{rms}(W^p, W^r) = \sqrt{\frac{1}{m} \sum_{i=1}^m (W_i^p - W_i^r)^2} \quad (5)$$

$$E_{map} = \frac{100\%}{m} \times \sum_{i=1}^m \left| \frac{W_i^p - W_i^r}{W_i^r} \right| \quad (6)$$

式中  $W^p$  表示模型预测的猪体质量, kg;  $W^r$  表示真实猪体质量, kg;  $m$  表示数据集中猪体质量的数目。

表5 不同特征提取网络的猪体质量测定模型结果

Table 5 Results of different feature extraction networks in mass measurement algorithm

骨干网络 BackBone network	训练集 Training set		验证集 Validation set		测试集 Testing set		平均预测速度 Average speed/ (s·帧 <sup>-1</sup> )
	均方根误差 Root mean square error/kg	平均绝对百分比误差 Mean absolute percentage error/%	均方根误差 Root mean square Error/kg	平均绝对百分比误差 Mean absolute percentage error/%	均方根误差 Root mean square error/kg	平均绝对百分比误差 Mean absolute percentage error/%	
ResNet	5.94	3.38	9.63	6.19	10.87	6.77	0.144
ConvNeXt	3.65	3.15	4.94	3.93	5.15	4.12	0.202
ResNet (Improved)	1.59	1.02	2.72	1.86	3.01	2.02	0.684

### 3.4 常态养殖下的 IMMM-GS 模型性能分析

为了评估 IMMM-GS 模型在常态养殖中的应用性能,挑选了 10 头母猪在 4 月 24 日至 7 月 29 日和 6 月 26 日至 9 月 29 日的常态视频数据进行分析。每天截取活动频繁的 14:00 至 16:00 的视频数据,将视频数据按帧切分成图,图 11 为部分母猪在 5 月 22 日至 6 月 2 号的部分视频数据截图。数据以天为单位输入到 IMMM-GS 模型中,将模型输出的平均值作为当天的体质量估测并绘制体质量增长曲线。在试验中考虑到母猪妊娠期间的日增重在 0.5~1.0 kg 之间,且频繁称量体质量会对母猪的健康造成负面影响,因此,每隔 5 d 对母猪进行 1 次称量。考虑到体质量测定模型在测试集上的均方根误差为 3.01 kg,

猪体质量测定算法在不同特征提取网络上的 RMSE 变化曲线如图 10 所示,改进后的 ResNet 网络收敛后的  $E_{rms}$  值明显低于另外两个网络,本算法选择在验证集上表现最优的模型作为最终算法模型。算法在测试集上的  $E_{rms}$ 、 $E_{map}$  和每幅图的平均预估速度如表 5 所示。本新设计网络比另外两个网络运算速度略有下降但在测试集上的  $E_{rms}$  为 3.01 kg, 比以 ConvNeXt 和 ResNet 为骨干网络的猪体质量测定算法降低了 2.14 kg 和 7.86 kg,  $E_{map}$  降低了 2.10% 和 4.75%。

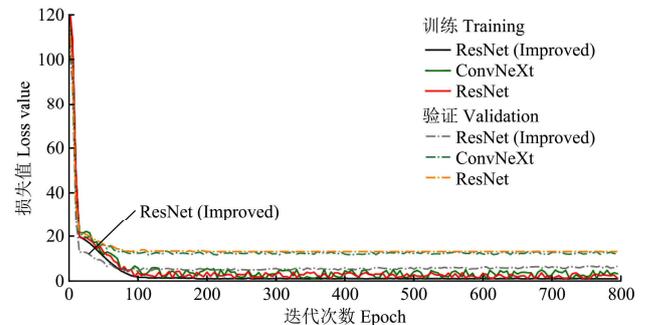


图10 猪体质量测定算法在不同特征网络的均方根误差曲线  
Fig.10 Loss function curves of pig mass measurement model for different feature extraction networks

而 5 d 通常不超过 5 kg 的增长率,有可能出现猪只失重等异常情况却被误差磨平的情况,因此将估重间隔延长为 10 d 做了试验分析。模型最终输出 10 头母猪的估测体质量和真实体质量的  $E_{mas}$  和相关系数如表 6 所示,  $E_{mas}$  平均值为 3.24 kg, 最大为 4.04 kg, 相关系数均超过 0.96。

表 6 显示 1 号母猪的误差最小,进一步分析该母猪估测体质量增长曲线和真实体质量增长曲线,试验结果如图 12 所示。结果表明,1 日内猪只体质量有 1~3 kg 的浮动,但是长时段看来两条曲线走势高度一致。因此,本文算法是可以真实反映出妊娠母猪体质量的增长曲线,表明模型达到较理想的测定效果,可以在实际生产中进行应用。

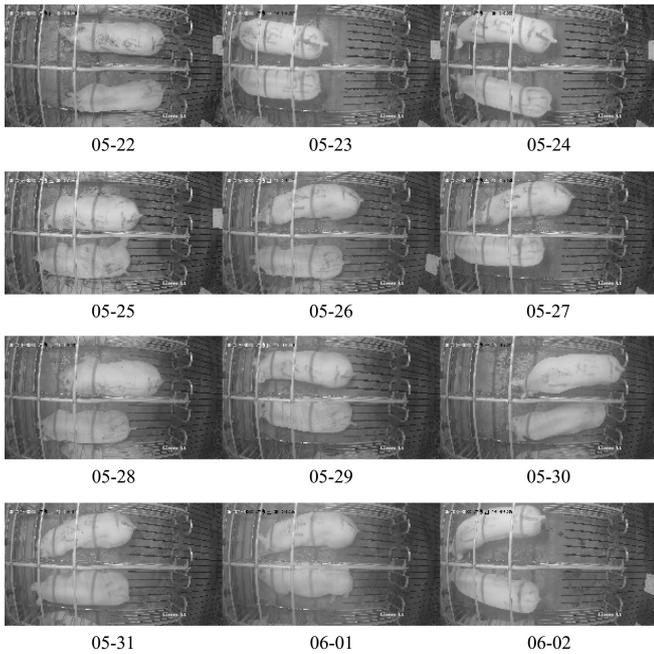


图 11 不同日期部分母猪视频数据截图

Fig.11 Screenshots of some sow video data on different dates

表 6 验证母猪的体质量预测精度

Table 6 Accuracy of mass prediction in validation sows

猪只编号 Pig ID	均方根误差 Root mean square error/kg	相关系数 Correlation coefficient
1	2.45	0.991
2	3.44	0.979
3	2.61	0.991
4	2.63	0.988
5	3.06	0.986
6	3.21	0.984
7	4.04	0.965
8	3.71	0.980
9	4.02	0.965
10	3.23	0.982

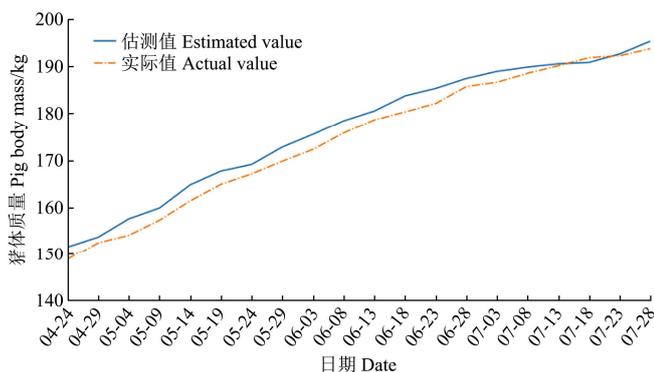


图 12 母猪估测体质量增长曲线与实际体质量增长曲线

Fig.12 Estimated body mass growth curve and actual body mass growth curve of sow

## 4 结论

针对常态养殖环境下围栏、食槽、排泄物等常见遮挡物带来的猪体质量测定干扰，本文基于深度学习技术，引入实例分割和关键点检测等深度学习先进技术来解决妊娠母猪体质量测定问题，提出一种妊娠母猪体质量测

定模型 IMM-GS，并用真实猪场 6 个月的常态视频数据进行了试验与验证。得出如下结论：

1) IMM-GS 模型使用实例分割算法和关键点检测算法剔除被遮挡的猪只，分割算法的精度达到 91.04%，关键点检测算法的精度达到了 89.59%，较好解决了常规遮挡问题，使本文方法更实用。

2) IMM-GS 模型引入多分支卷积、depthwise 卷积、逆瓶颈层等结构对特征提取网络 ResNet 进行改进，模型在测试集上的均方根误差为 3.01 kg，相较于以 ConvNeXt 和 ResNet 为骨干网络的模型降低 2.14 和 7.86 kg，模型精度得到较大提升。

3) IMM-GS 模型在利用普通视频图像进行质量估测性能表现较好。试验对 10 头妊娠母猪进行了 3 个月的猪体质量跟踪监测验证，在图像大小为 2 688×1 520 的情况下，每幅图像的平均估算速度为 0.684 s，估测质量与真实质量的均方根误差平均值为 3.24 kg，计算速度与精度基本满足实时运算需求。

因此，本文模型可用于长期持续监测猪体质量，能为评估母猪妊娠期体质量增长规律、母猪妊娠发育状况、估测预产期和产仔数等繁殖性能提供数据支撑，可为母猪养殖精准化管理提供技术支持，具有广阔的应用前景。

## [参考文献]

- [1] Douglas S L, Szyszka O, Stoddart K, et al. Animal and management factors influencing grower and finisher pig performance and efficiency in European systems: A meta-analysis[J]. *Animal*, 2015, 9(7): 1210-1220.
- [2] Parsons D J, Green D M, Schofield C P, et al. Real-time control of pig growth through an integrated management system[J]. *Biosystems Engineering*, 2007, 96(2): 257-266.
- [3] 杨艳, 滕光辉, 李保明, 等. 基于计算机视觉技术估算种猪体重的应用研究[J]. *农业工程学报*, 2006, 22(2): 127-131.
- [4] Yang Yan, Teng Guanghui, Li Baoming, et al. Measurement of pig weight based on computer vision[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2006, 22(2) : 127-131. (in Chinese with English abstract).
- [4] 张建龙, 冀横溢, 滕光辉. 基于深度卷积网络的育肥猪体重估测[J]. *中国农业大学学报*, 2021, 26(8): 111-119.
- [5] Zhang Jianlong, Ji Hengyi, Teng Guanghui. Weight estimation of fattening pigs based on deep convolutional network[J]. *Journal of China Agricultural University*, 2021, 26(8): 111-119. (in Chinese with English abstract)
- [5] 王琳, 孙传恒, 李文勇, 等. 基于深度图像和 BP 神经网络的肉鸡体质量估测模型[J]. *农业工程学报*, 2017, 33(13): 199-205.
- [6] Wang Lin, Sun Chuanheng, Li Wenyong, et al. Establishment of broiler quality estimation model based on depth image and BP neural network[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2017, 33(13): 199-205. (in Chinese with English abstract).
- [6] Wang Z, Shadpour S, Chan E, et al. ASAS-NANP SYMPOSIUM: Applications of machine learning for

- livestock body weight prediction from digital images[J]. *Journal of Animal Science*, 2021, 99(2): 1-15.
- [7] Jun K, Kim S J, Ji H W. Estimating pig weights from images without constraint on posture and illumination[J]. *Computers and Electronics in Agriculture*, 2018, 153: 169-176.
- [8] Bhoj S, Tarafdar A, Chauhan A, et al. Image processing strategies for pig liveweight measurement: Updates and challenges[J]. *Computers and Electronics in Agriculture*, 2022, 193: 106693.
- [9] 李卓, 毛涛涛, 刘同海, 等. 基于机器视觉的猪体质量估测模型比较与优化[J]. *农业工程学报*, 2015, 31(2): 155-161.  
Li Zhuo, Mao Taotao, Liu Tonghai, et al. Comparison and optimization of pig mass estimation models based on machine vision[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2015, 31(2): 155-161. (in Chinese with English abstract)
- [10] 初梦苑, 刘刚, 司永胜, 等. 基于三维重建的奶牛体重预估方法[J]. *农业机械学报*, 2020, 51(S1): 385-391.  
Chu Mengyuan, Liu Gang, Si Yongsheng, et al. Predicting method of dairy cow weight based on three-dimensional reconstruction[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2020, 51(S1): 385-391. (in Chinese with English abstract)
- [11] Shahinfar S, Al-Mamun H A, Park B, et al. Prediction of marbling score and carcass traits in Korean Hanwoo beef cattle using machine learning methods and synthetic minority oversampling technique[J]. *Meat Science*, 2020, 161: 107997.
- [12] Le Cozler Y, Allain C, Xavier C, et al. Volume and surface area of Holstein dairy cows calculated from complete 3D shapes acquired using a high-precision scanning system: Interest for body weight estimation[J]. *Computers and Electronics in Agriculture*, 2019, 165: 104977.
- [13] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.
- [14] Gu J, Wang Z, Kuen J, et al. Recent advances in convolutional neural networks[J]. *Pattern Recognition*, 2018, 77: 354-377.
- [15] Dan B J, Dominiak K, Pedersen L J. Automatic estimation of slaughter pig live weight using convolutional neural networks[C]// II International Conference on Agro BigData and Decision Support Systems in Agriculture. Lleida: Universitat de Lleida, 2018: 1-4.
- [16] Cang Y, He H, Qiao Y. An intelligent pig weights estimate method based on deep learning in sow stall environments[J]. *IEEE Access*, 2019, 7: 164867-164875.
- [17] Zhang J, Zhuang Y, Ji H, et al. Pig weight and body size estimation using a multiple output regression convolutional neural network: A fast and fully automatic method[J]. *Sensors*, 2021, 21(9): 3218.
- [18] Meckbach C, Tiesmeyer V, Traulsen I. A promising approach towards precise animal weight monitoring using convolutional neural networks[J]. *Computers and Electronics in Agriculture*, 2021, 183: 106056.
- [19] He H, Qiao Y, Li X, et al. Automatic weight measurement of pigs based on 3D images and regression network[J]. *Computers and Electronics in Agriculture*, 2021, 187: 106299.
- [20] 肖德琴, 黄顺彬, 殷建军, 等. 基于嵌入式应用的高分辨率农业图像采集节点设计[J]. *农业机械学报*, 2014, 45(2): 276-281.  
Xiao Deqin, Huang Shunbin, Yin Jianjun, et al. Development of high-resolution agricultural image capture node based on embedded system. *Transactions of the Chinese Society for Agricultural Machinery*, 2014, 45(2): 276-281. (in Chinese with English abstract)
- [21] Lin T Y, Maire M, Belongie S, et al. Microsoft coco: Common objects in context[C]//European conference on computer vision. Spring, Cham, 2014: 740-755.
- [22] He K, Gkioxari G, Dollár P, et al. Mask R-CNN[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 42(2): 386-397.
- [23] 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. Piscataway: IEEE, 2016: 770-778.
- [24] Gao S H, Cheng M M, Zhao K, et al. Res2net: A new multi-scale backbone architecture[J]. *IEEE transactions on pattern analysis and machine intelligence*, 2019, 43(2): 652-662.
- [25] Liu Z, Mao H, Wu C Y, et al. A convnet for the 2020s[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2022: 11976-11986.
- [26] Xie S, Girshick R, Dollár P, et al. Aggregated residual transformations for deep neural networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2017: 1492-1500.
- [27] Sandler M, Howard A, Zhu M, et al. Mobilenetv2: Inverted residuals and linear bottlenecks[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Piscataway: IEEE, 2018: 4510-4520.
- [28] Liu Z, Lin Y, Cao Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE, 2021: 10012-10022.

## Intelligent mass measurement model for gestating sows under normality breeding

Xiao Deqin<sup>1</sup>, Liu Junbin<sup>1</sup>, Liu Youfu<sup>1</sup>, Huang Yigui<sup>1</sup>, Tan Zujie<sup>1</sup>, Xiong Benhai<sup>2</sup>

(1. Key Laboratory of Smart Agricultural Technology in Tropical South China Ministry of Agriculture and Rural Affairs, South China Agricultural University, Guangzhou 510642, China;

2. Institute of Animal Science, Chinese Academy of Agricultural Sciences, Beijing 100193, China)

**Abstract:** Body mass growth of gestating sows is an important indicator of their health status and reproductive performance. Computer vision-based contactless pig body mass measurement methods can effectively reduce stress and have become a hot topic in recent years. However, most current computer vision-based contactless pig mass measurement methods require data acquisition and mass measurement calculation under specific ideal experimental environments and lack application in usual breeding environments. In this paper, an Intelligent Mass Measurement Model for Gestating Sows (IMMM-GS) based on deep learning is proposed based on video image data under usual farming by using instance segmentation and keypoint detection algorithms in computer vision technology. The model includes three main sub-algorithms to solve the typical occlusion problem in the normal environment, the first is the pig instance segmentation algorithm based on Mask R-CNN, the second is the pig keypoint detection algorithm based on Keypoint R-CNN, and the last is the pig mass measurement algorithm based on modified ResNet. The instance segmentation algorithm is used to segment the pigs from the image to reduce the influence of the image background on the mass measurement, and the keypoint detection algorithm is used to eliminate incomplete pigs to ensure that there are no incomplete pigs in the dataset. In this paper, video data and mass data of 48 gestating sows for six months are used for dataset construction and experimental analysis. The datasets were collected at a commercial pig farm in Guangzhou City, Guangdong Province, China in 2022. A camera was deployed to the slide rail to get real-time video data of the pigs, and the test pigs were weighed every five days. The IMMM-GS model used the PyTorch deep learning framework, MMDetection framework, and MMPose framework. The experiment was carried out on the Ubuntu18.04 system with a CPU of Intel Core i7-9700 and a GPU (graphics processing units) of NVIDIA A30 whose memory was 24 GB. The root mean square error of the model on the test set was 3.01 kg, which was 2.14 kg and 7.86 kg lower compared to the model with ConvNeXt and ResNet as the backbone network. And the mean absolute percentage error was 2.02%, which was 2.10% and 4.75% lower than the model with ConvNeXt and ResNet as the backbone network. The model constructed in this paper also monitored the mass of ten gestating sows for three months with an image size of 2 688×1 520, the average measurement speed per image was 0.684 s and the root mean square error between the estimated mass and the actual mass was 3.24 kg and the computational speed and accuracy met the demand of real-time computing. Therefore, the author thought that the IMMM-GS model could provide data support for estimating the reproductive performance such as the mass growth pattern of sows during gestation, the developmental status of gestating sows, and estimating the expected farrowing period and litter size in real-time using the standing video for a long time, and has broad application prospects.

**Keywords:** computer vision; deep learning; gestating sow; mass measurement; convolutional neural network