

基于关键点和步行特征的猪只跛行检测方法

杨秋妹^{1,2} 黄森鹏^{1,2} 肖德琴^{1,2} 惠向阳^{1,2} 黄一桂^{1,2} 李文刚^{1,2}

(1. 华南农业大学数学与信息学院, 广州 510642; 2. 农业农村部华南热带智慧农业技术重点实验室, 广州 510642)

摘要: 猪只跛行问题为猪场的生产和管理带来了挑战,因此准确检测猪只跛行情况至关重要。目前猪场主要依赖人工观察和记录,效率低耗时长,且可能存在主观误差。鉴于此,提出一种基于关键点和步行特征的猪只跛行检测方法。首先,定义并确定了猪只的关键点信息,关键点包括猪只的腿、膝盖、背部等重要部位。基于关键点,采用改进 YOLO v8n-pose 模型进行检测。该模型在 YOLO v8n-pose 的基础上,在颈部引入 BiFPN 双向特征金字塔网络进行多尺度特征融合,同时在骨干网络中引入 RepGhost 网络,以降低特征提取网络的参数量和浮点运算量。然后利用检测出的关键点坐标计算猪只的步长、膝盖弯曲程度和背部曲率等步行特征,并将这些特征输入到 K 最近邻算法进行跛行与非跛行的分类。实验结果表明,改进 YOLO v8n-pose 模型平均精度均值 (mAP) 达到 92.4%,比原始 YOLO v8n-pose 模型提高 4.2 个百分点。与其他关键点检测模型 (HRNet-w32、Lite-HRNet、ResNet50、ViPNAS 和 Hourglass) 相比,mAP 分别提高 10.2、11.6、14.2、11.8、12.5 个百分点。K 近邻算法在猪只跛行测试集上的检测精度为 81.7%,比 BP 算法、Decision Tree 算法和 SVM 算法分别提高 1.5、11.3、6.5 个百分点。以上结果表明,本文提出的猪只跛行检测方法可行,能够为猪场检测提供技术支持。

关键词: 猪只; 跛行; 关键点检测; YOLO v8n-pose; 步行特征

中图分类号: TP391

文献标识码: A

文章编号: 1000-1298(2025)05-0466-09

OSID:



Pig Lameness Detecting Method Based on Key Points and Walking Features

YANG Qiumei^{1,2} HUANG Senpeng^{1,2} XIAO Deqin^{1,2} HUI Xiangyang^{1,2} HUANG Yigui^{1,2} LI Wen'gang^{1,2}

(1. College of Mathematics and Informatics, South China Agricultural University, Guangzhou 510642, China

2. Key Laboratory of Smart Agricultural Technology in Tropical South China,

Ministry of Agriculture and Rural Affairs, Guangzhou 510642, China)

Abstract: The problem of lameness in pigs presents significant challenges to the production and management of pig farms, making accurate detection of pig lameness crucial. Currently, pig farms primarily rely on manual observation and recording, which is inefficient, time-consuming, and prone to subjective judgment errors. In light of this, a method for detecting pig lameness based on key points and walking characteristics was proposed. Firstly, key point information for pigs was defined and determined, including critical parts such as the legs, knees, and back. Based on these key points, an improved YOLO v8n-pose model was employed for detection. This model built upon the original YOLO v8n-pose by introducing a bidirectional feature pyramid network (BiFPN) at the neck for multi-scale feature fusion and incorporating a RepGhost network into the backbone to reduce the parameter count and computational complexity of the feature extraction network. Then using the coordinates of the detected key points, walking characteristics such as stride length, knee bending degree, and back curvature were calculated. These features were inputted into a K-nearest neighbors (KNN) algorithm to classify pigs as lame or non-lame. Experimental results showed that the improved YOLO v8n-pose model achieved a mean average precision (mAP) of 92.4%, which was 4.2 percentage points higher than the detection accuracy of the original YOLO v8n-pose model. Compared with other key point detection models (HRNet-w32, Lite-HRNet, ResNet50, ViPNAS, and Hourglass), the mAP was improved by 10.2, 11.6, 14.2, 11.8 and 12.5 percentage points, respectively. The KNN algorithm achieved a detection accuracy of 81.7% on the

收稿日期: 2024-07-18 修回日期: 2024-08-26

基金项目: 广东省重点领域研发计划项目 (2023B0202140001) 和国家重点研发计划项目 (2021YFD2000802)

作者简介: 杨秋妹 (1983—), 女, 讲师, 博士, 主要从事农业图像视频处理研究, E-mail: yqmbegonia@163.com

通信作者: 肖德琴 (1970—), 女, 教授, 博士生导师, 主要从事物联网和农业图像视频处理研究, E-mail: deqinx@scau.edu.cn

pig lameness test set, which was 1.5, 11.3 and 6.5 percentage points higher than that of the BP algorithm, Decision Tree algorithm, and SVM algorithm, respectively. These results demonstrated that the proposed method for detecting pig lameness was feasible and can provide technical support for pig farm detection.

Key words: pig; lameness; keypoint detection; YOLO v8n – pose; gait features

0 引言

跛行是影响猪只健康和发育的常见问题,严重影响猪只福利和养殖经济效益。及早发现并治疗猪只蹄部和腿部异常,可以减少损失^[1-2]。当猪只跛行时,可能表现为不愿站立、腿部摆动不协调或幅度减小、膝盖弯曲角度偏小,以及背部轻微拱起等现象^[3-4]。因此,通过观察这些表现可以判断猪只是否跛行。传统的动物跛行检测主要依赖人工,存在成本高和主观误差等问题,急需自动化检测方法。目前,非人工检测方法分为接触式和非接触式。接触式方法通过传感器穿戴设备检测运动数据识别跛行^[5-8]。尽管接触式方法有效,但易受环境影响,且可能导致动物应激。

随着深度学习的发展,越来越多的研究转向利用计算机视觉技术进行非接触式动物跛行检测^[9-10]。例如,通过摄像头记录奶牛的行走视频,提取背部轮廓、步态特征,并使用 SVM 或 LSTM 等算法进行分类^[11-13]。LI 等^[14]通过改进的 SOLO v2 网络和匈牙利算法对视频中的多头奶牛进行分割和跟踪,使用 Canny 算法提取奶牛颈部和背部特征进行跛行检测。康熙等^[15]利用可见光图像和红外图像记录奶牛运动视频,计算奶牛弓背曲率以检测跛行。杜粤猛等^[16]通过 Faster RCNN 和 ResNet101 网络模型构建奶牛姿态估计模型,使用 1-D 卷积分类模型根据奶牛行走时膝关节的角度特征识别跛行。基于关键点的研究方法也被用于检测动物跛行,王祥等^[17]通过猪只的关键轮廓点模型采集步态信息,并利用这些信息判断猪是否跛行。

综上所述,基于计算机视觉技术对动物进行跛行检测是可行的,并且相较于传统的人工观察和传感器方法具有显著优势。尽管计算机视觉在动物行为分析中已取得一定进展,但目前针对猪只跛行检测的研究仍较为有限,许多先进的计算机视觉方法尚未充分应用于此领域^[18-20]。传统的目标检测和实例分割方法通常优先捕获猪只的边界和轮廓信息,难以准确识别猪只的身体姿态和四肢变化。相比之下,关键点检测技术更擅长捕捉猪只身体姿态的细微变化,特别是在跛行过程中,猪只通常表现出背部弯曲、膝关节异常及步长不一致等特征。因此,

本文提出一种基于关键点和步行特征的猪只跛行检测方法。在 YOLO v8n – pose 的基础上,结合 BiFPN 双向特征金字塔和 RepGhost 网络来检测猪只的关键点,并利用这些关键点的检测结果计算猪只的步行特征,以期实现对跛行和非跛行猪只的分类识别。

1 数据来源与数据集构建

1.1 数据来源

实验数据于 2023 年 8 月在广东省云浮市温氏集团旗下农户猪场拍摄。为捕捉猪只行走特征,从猪只侧面进行拍摄。如图 1 所示,采用人工驱赶方式,让猪只通过通道,摄像头位置垂直于猪只行走方向,离地高度约为 0.8 m。帧率为 25 f/s,分辨率为 3 840 像素 × 2 160 像素。




图 1 猪只数据拍摄示意图
Fig. 1 Example diagram of pig data capture

1.2 数据集构建

1.2.1 关键点数据集构建

从收集的视频数据中隔 25 帧截取 1 幅图像,去除相似的图像后共获得 1 623 幅,其中 600 幅作为测试集。对剩余的 1 023 幅图像通过随机添加高斯噪声、调整亮度、平移等方式进行数据增强,形成训练集,图像包含跛行和非跛行的情况。使用 Labelme 软件标注,通过 group_id 来区分关键点的可见性,0 表示不在图中,1 表示被遮挡,2 表示可见。由于所选图像中猪只均完整出现,因此排除 group_id 为 0 的情况。随后,将标注数据转换为 YOLO 格式。为研究猪只跛行,标注了猪只的四肢和上半身的 17 个关键点,如图 2 所示。具体关键点和标注位置详见表 1。

1.2.2 跛行检测数据集构建

将采集到的数据切分成若干片段,每个片段包含 50 帧图像,确保每个片段中猪完成了一个完整的行走动作,其中包含 101 个跛行片段和 114 个非跛




图2 猪只关键点标注示意图

Fig.2 Example diagram of pig keypoint annotation

表1 关键点信息

Tab.1 Keypoint information

坐标	部位	标注位置
(x_1,y_1)	鼻子	鼻尖最前端(通常为头部最突出的位置)
(x_2,y_2)	头部	眼睛偏下一点的位置(从侧面)
(x_3,y_3)	颈部	脖子中间区域(连接头部与身体的部分)
(x_4,y_4)	背部	脊椎中间、微微拱起的位置
(x_5,y_5)	臀部	尾巴根部
(x_6,y_6)	右肩部	右前肢与躯干连接中点处
(x_7,y_7)	右前膝	腿关节处(右前腿弯曲处)
(x_8,y_8)	右前蹄	右前脚蹄尖(最接近地面的位置)
(x_9,y_9)	右后臀	右后肢与躯干连接处(靠近臀部右侧边缘)
(x_{10},y_{10})	右后膝	右后腿膝盖外侧中央(腿关节弯曲处)
(x_{11},y_{11})	右后蹄	右后脚蹄尖(最接近地面的位置)
(x_{12},y_{12})	左前肩	左前肢与躯干连接中点处
(x_{13},y_{13})	左前膝	腿关节处(左前腿弯曲处)
(x_{14},y_{14})	左前蹄	左前脚蹄尖(最接近地面的位置)
(x_{15},y_{15})	左后臀	左后肢与躯干连接处(靠近臀部左侧边缘)
(x_{16},y_{16})	左后膝	左后腿膝盖外侧中央(腿关节弯曲处)
(x_{17},y_{17})	左后蹄	左后脚蹄尖(最接近地面的位置)

行片段。将跛行片段和非跛行片段分别按比例 7:3 划分,得到数据集情况如表 2 所示。

2 猪只跛行检测方法

2.1 研究方法

猪只跛行检测方法是基于跛行特征实现的,猪




图3 技术路线图

Fig.3 Technical roadmap

表2 跛行检测数据集样本数

Tab.2 Lameness detection dataset

数据集	训练集	测试集
跛行	70	31
非跛行	79	35
总计	149	66

只跛行表现为步态不稳、步幅缩短、行动困难、背部微弓和头部低垂等特征^[21]。如图 3 所示,本文设计了一种基于关键点和步行特征的跛行检测方法。首先,通过 YOLO v8n-pose 模型检测出猪只步行的关键点,同时引入 BiFPN 特征融合网络和 RepGhost 轻量化网络,以提升关键点特征提取和模型精度。然后利用所获取的关键点信息计算猪只行走过程中的步长、背部弯曲程度和膝盖弯曲程度。最后,利用机器学习方法对计算得到的步行特征进行分类检测。

2.2 基于 YOLO v8n-pose 的猪只关键点检测网络

YOLO v8-pose 相较于 YOLO v5 和 YOLO v7 等算法在速度和精度上均有显著提升,可用于目标检测、实例分割和关键点检测等领域^[22]。YOLO v8-pose 共有 n、s、m、l、x 5 个版本,其中 YOLO v8n-pose 在保持参数量和速度较优的情况下,仍能准确检测。因此,本文选择 YOLO v8n-pose 作为猪只的关键点检测模型。

如图 4 所示,YOLO v8n-pose 主要由输入层、主干网络(Backbone)、颈部网络(Neck)和输出层组成。主干网络负责特征提取,Conv 模块对输入图像进行卷积操作以提取特征,C2f 模块对数据进行特征转换和分支处理,从而提高网络对复杂数据的建模能力,丰富特征表达。最后,SPPF 模块通过将特征池化到固定大小的特征图,加速计算^[23-24]。而 Neck 网络主要是将来自不同层级的特征进行融合,以捕捉不同尺度下的目标信息。

2.3 YOLO v8n-pose 模型改进

2.3.1 BiFPN 双向特征金字塔

BiFPN 可以实现快速的多尺度特征融合,是一




图 4 改进的 YOLO v8n - pose 网络结构图

Fig. 4 Diagram of improved YOLO v8n - pose network structure

种高效的加权双向特征金字塔网络^[25]。如图 5a、5b 所示,原始 YOLO v8 - pose 采用的是 PAN - FPN 的双向融合金字塔结构,其中 FPN 引入自顶向下的路径来融合多尺度特征,PAN 对 FPN 进行补充,引入自底向上的路径,融合不同层次的特征图。然而,为了进一步提升特征融合效率和检测性能,本文将 PAN - FPN 替换为 BiFPN。如图 5c 所示,BiFPN 允许特征信息在自顶向下和自底向上两个方向流动和融合,使网络能够更有效地利用不同尺度的信息,从而提高检测的性能^[26]。BiFPN 通过双向融合机制,更全面地整合不同层级的特征信息,确保特征图的高效表达和利用。同时,BiFPN 引入了加权融合并简化了融合路径,能够根据训练过程中的优化需求,动态调整各特征图的贡献,减少计算复杂度,从而提升融合效果和模型性能。




图 5 特征结构图

Fig. 5 Feature structure diagram

在猪只行走过程中,身体不同部位的关键点特征尺度可能存在着差异,准确捕捉这些不同尺度的

特征对于提高检测精度至关重要。与 Concat 操作相比,BiFPN 能够在处理不同尺度的特征时表现更优,能够更好地捕捉和利用大小不同的目标信息,进一步提升检测精度,因此本文使用 BiFPN 替换掉颈部中的 Concat 操作,如图 4 所示。

2.3.2 RepGhost 网络

注意力机制是一种智能过滤机制,可以有选择地从大量数据中挑选出关键信息,将注意力集中在这些关键信息上,同时忽略大部分不相关或不太重要的数据,从而提高模型的精度或减少计算量^[27]。RepGhost 模块在 Ghost 模块^[28]的基础上引入了重参数化技术,有效降低了模型的计算复杂度。如图 6 所示,基于原始的 Ghost 模块,首先将 Ghost 中的 Concat 操作替换成 add 操作,以得到更高的效率。然后再将 add 操作移动到 ReLU 操作后面,同时将归一化操作 BN 添加到重参数化的结构分支中。最后为了能够更加快速推断,将图 6d 中的模块融合成图 6e 中的结构,最终仅包含常规卷积和 ReLU^[29]。




图 6 RepGhost 模块

Fig. 6 RepGhost module

如图 7 所示,通过替换 Ghost 模块为 RepGhost 模块构建 RepGhost 网络。图 7b、7c 分别为 RepGhost 网络在训练和推理时的结构。在训练阶段,输入特征通过一个 1×1 的 Conv 层和 ReLU 激活函数,然后经过带有批量归一化(BN)操作的 RepGhost 模块。接着,通过下采样和 SE 模块增强通道特征。最后,经过另一个带有 BN 操作的 RepGhost 模块,与通过 SBlock 模块处理后的原始输入特征融合,输出最终特征。在推理阶段,

RepGhost 模块通过参数融合将深度卷积(dConv)和 BN 转换为等效的深度可分离卷积。利用结构重参数化,RepGhost 能够合并不同的特征图,从而减少特征信息的丢失,提高推理精度。

如图 4 所示,使用 RepGhost 网络替换 YOLO v8 - pose 中 C2f 模块的 Bottleneck 网络,构成了 C2f_RepGhost 模块。并用 C2f_RepGhost 模块替换了 Backbone 网络中第 4 层和第 6 层的 C2f 模块。




图 7 RepGhost 网络图

Fig. 7 RepGhost network diagram

2.4 步行特征计算

对于跛脚猪只,由于蹄部或腿部疼痛,行走时可能会表现为步长变长或变短。此外,受影响的腿部对应的膝盖也可能出现异常弯曲。跛行的猪只还会通过拱起背部来减轻疼痛。本文利用步长、膝盖弯曲程度和背部弯曲程度 3 个变量变化规律来探讨猪只跛行的检测方法,计算特征所用的 (x_i, y_i) 对应表 1 中的关键点信息,7 个特征如表 3 所示。

表 3 步行特征描述		
Tab. 3 Description of walking features		
编号	特征	描述
F_1	前步长	两个前蹄间距离
F_2	后步长	两个后蹄间距离
F_3	右前膝盖角度	右肩部、右前膝和右前蹄 3 个部位间角度
F_4	右后膝盖角度	右后臀、右后膝和右后蹄 3 个部位间角度
F_5	左前膝盖角度	左肩部、左前膝和左前蹄 3 个部位间角度
F_6	左后膝盖角度	左后臀、左后膝和左后蹄 3 个部位间角度
F_7	背部弯曲程度	颈部、背部和臀部形成的弧的弯曲程度

步长特征可分为两个前蹄的步长 F_1 和两个后

蹄的步长 F_2 ,对应的步长公式为

$$F_1 = \sqrt{(x_8 - x_{14})^2 + (y_8 - y_{14})^2} \tag{1}$$

$$F_2 = \sqrt{(x_{11} - x_{17})^2 + (y_{11} - y_{17})^2} \tag{2}$$

膝盖角度用来量化行走过程中猪只的腿部弯曲程度,即

$$F_3 = \arccos \frac{(x_7 - x_6, y_7 - y_6)(x_7 - x_8, y_7 - y_8)}{|(x_7 - x_6, y_7 - y_6)| |(x_7 - x_8, y_7 - y_8)|} \frac{180}{\pi} \tag{3}$$

$$F_4 = \arccos \frac{(x_{10} - x_9, y_{10} - y_9)(x_{10} - x_{11}, y_{10} - y_{11})}{|(x_{10} - x_9, y_{10} - y_9)| |(x_{10} - x_{11}, y_{10} - y_{11})|} \frac{180}{\pi} \tag{4}$$

$$F_5 = \arccos \frac{(x_{13} - x_{12}, y_{13} - y_{12})(x_{13} - x_{14}, y_{13} - y_{14})}{|(x_{13} - x_{12}, y_{13} - y_{12})| |(x_{13} - x_{14}, y_{13} - y_{14})|} \frac{180}{\pi} \tag{5}$$

$$F_6 = \arccos \frac{(x_{16} - x_{15}, y_{16} - y_{15})(x_{16} - x_{17}, y_{16} - y_{17})}{|(x_{16} - x_{15}, y_{16} - y_{15})| |(x_{16} - x_{17}, y_{16} - y_{17})|} \frac{180}{\pi} \tag{6}$$

通过三点法计算离散曲率,计算颈部、背部和臀部 3 个点之间距离,并使用反余弦函数计算对应的角度,最终利用曲率计算公式求出背部所在部位的曲率 F_7 ,即

$$F_7 = \frac{2\sin\theta}{L_3}$$

(7)

其中

$$\theta = \arccos \frac{L_1^2 + L_2^2 - L_3^2}{2L_1L_2}$$

(8)

$$L_1 = \sqrt{(x_4 - x_3)^2 + (y_4 - y_3)^2}$$

(9)

$$L_2 = \sqrt{(x_4 - x_5)^2 + (y_4 - y_5)^2}$$

(10)

$$L_3 = \sqrt{(x_3 - x_5)^2 + (y_3 - y_5)^2}$$

(11)

式中 L_1 ——颈部和背部间距离
 L_2 ——臀部和背部间距离
 L_3 ——颈部和臀部间距离
 θ ——颈部、背部和臀部在背部处的夹角

2.5 跛行检测方法

通过上述方法构建步行特征,对于每一帧数据,提取出 2 个前蹄的步长、2 个后蹄的步长、4 条腿的膝盖弯曲角度以及背部曲率,共 7 个特征,构成特征 $F_i (i = 1, 2, \cdots, 7)$ 。K 最近邻算法 (K-nearest neighbors, KNN) 是一种基本的分类和回归算法。对于给定的有标签样本集 D ,当输入一个待分类的无标签样本时,该算法将该样本的每一个特征与样本集 D 中的数据进行比较,计算它与样本集中其他样本距离,并选择距离最近的 k 个样本。然后根据这 k 个样本中出现次数最多的标签,决定待分类样本的类别标签。本文使用的距离度量是欧氏距离,公式为

$$D(m_a, m_b) = \sqrt{\sum_{i=1}^n (F_i^a - F_i^b)^2}$$

(12)

式中 m_a, m_b ——样本 a, b
 F_i^a, F_i^b ——样本 m_a, m_b 的第 i 个特征
 n ——特征维度

3 实验

3.1 实验环境及参数设置

实验基于 Pytorch 和 Python 3.9,操作平台为 64 位 Windows 10,显卡为 RTX3060,内存为 12 GB,处理器为 Intel(R) Core(TM) i7-10700 CPU@2.90 GHz。YOLO v8-pose 模型超参数如表 4 所示。

3.2 评价指标

为评估 YOLO v8-pose 模型的性能,利用关键点相似度 (OKS) 来衡量预测关键点和真实关键点间的差距。设置阈值为 0.5,当 OKS 大于阈值时判定

表 4 YOLO v8-pose 训练参数
Tab.4 YOLO v8-pose training parameters

参数	数值
批次大小 (batch_size)	16
训练轮次 (epoch)	300
学习率 (lr)	0.01
权重衰减 (weight_decay)	0.000 5
动量 (momentum)	0.937

为检测正确,通过平均精度均值 (mean Average Precision, mAP) 和召回率 (Recall, R) 对关键点检测模型进行评估。对于 KNN 分类模型,使用准确率 (Accuracy) 进行评估。

3.3 YOLO v8-pose 性能评估

3.3.1 消融实验

为提高猪只关键点检测模型的精度并减少计算量,对模型进行改进,引入 RepGhost 网络和 BiFPN 双向特征金字塔。为说明本文改进的有效性,进行消融实验,实验结果如表 5 所示。原 YOLO v8n-pose 在测试集上的 mAP 和召回率分别为 88.2% 和 86.9%。当模型引入 RepGhost 模块后,召回率下降 1.5 个百分点,而 mAP 提升 0.7 个百分点,同时参数量和浮点运算量分别下降 2×10^5 、 6×10^8 。在模型中引入 BiFPN 模块时,模型的 mAP 相比原模型提高 1 个百分点,参数量和浮点运算量保持不变。将 RepGhost 和 BiFPN 模块一起添加到 YOLO v8n-pose 后,相较于原模型,mAP 提高 4.2 个百分点,而召回率提升 0.9 个百分点,同时参数量和浮点运算量分别下降 2×10^5 、 6×10^8 。综合而言,在 YOLO v8n-pose 中添加 RepGhost 和 BiFPN 模块,不仅显著提升了模型 mAP 和召回率,还有效减少了参数量和浮点运算量,实现了性能和效率的双重优化。

表 5 消融实验结果
Tab.5 Results of ablation experiments

模型	mAP/%	R/%	参数量	浮点运算量
YOLO v8n-pose	88.2	86.9	3.3×10^6	9.2×10^9
+ RepGhost	88.9	85.4	3.1×10^6	8.6×10^9
+ BiFPN	89.2	85.3	3.3×10^6	9.2×10^9
+ RepGhost + BiFPN	92.4	87.8	3.1×10^6	8.6×10^9

3.3.2 不同模型对比实验

为更好地验证本文算法的性能,将改进模型与其他关键点检测模型 (HRNet-w32^[30]、Lite-HRNet^[31]、ResNet50^[32]、ViPNAS^[33]、Hourglass^[34]),在同一数据集下进行对比,结果如表 6 所示。

由表 6 可知,模型 HRNet-w32、Lite-HRNet、ResNet50、ViPNAS 和 Hourglass 的 mAP 分别为 82.2%、80.8%、78.2%、80.6% 和 79.9%。改进

表 6 不同模型对比结果

Tab. 6 Comparison results of different models %

模型	mAP	R
HRNet - w32	82. 2	83. 0
Lite - HRNet	80. 8	82. 3
ResNet50	78. 2	80. 3
ViPNAS	80. 6	81. 7
Hourglass	79. 9	81. 2
改进 YOLO v8 - pose	92. 4	87. 8

YOLO v8 - pose 模型 mAP 和召回率均优于上述对比模型,mAP 和召回率分别达到 92. 4% 和 87. 8%。相比 HRNet - w32 模型,mAP、召回率分别高出 10. 2、4. 8 个百分点。与 ResNet50 模型相比,改进模型 mAP、召回率分别高出 14. 2、7. 5 个百分点。综上所述,YOLO v8 - pose 模型及其改进版本在猪只关键点检测方面均优于其他关键点检测模型。

3. 4 猪只跛行检测模型评估

选用 KNN 算法对猪只步行特征进行分类检测。在 KNN 算法中,K 值的选择至关重要,取值范围为 1 ~ 17^[35]。为选取最佳 K 值,对该范围内每个 K 值逐一验证,结果如图 8 所示。当 K 取 1 时,KNN 算法对猪只跛行的准确率达到最高,为 81. 7%。




图 8 不同 K 值的 KNN 精度曲线

Fig. 8 Accuracy graph for different values of K in K-nearest neighbors

为验证分类算法的有效性,将 KNN 算法与 BP 算法、Decision Tree、SVM 进行对比。BP 算法的准确率为 80. 2%,比 KNN 算法低 1. 5 个百分点。Decision Tree 算法和 SVM 算法的准确率分别为 70. 4% 和 75. 2%,分别比 KNN 算法低 11. 3、6. 5 个

百分点。
3. 5 不同步行特征对跛行检测的影响

将猪只的步长、背部曲率和膝盖弯曲程度作为关键特征,用以检测猪只是否跛行。为探究这 3 个特征对跛行检测的有效性,采用 KNN 算法对每个特征单独进行训练和检测。单独使用膝盖弯曲程度、背部曲率和步长作为特征时,准确率分别达到 57. 7%、77. 5% 和 69. 0%。这表明,每个特征都在一定程度上对猪只跛行检测起到了作用。将所有特征结合起来进行跛行检测时,准确率达到 81. 7%。这表明,结合多个特征进行跛行检测比单独使用任一特征更为有效。这可能是因为不同特征之间存在相关性,结合起来可以提供更全面、更准确的信息,从而提高了跛行检测的准确性。因此,综合利用猪只的步长、背部曲率和膝盖弯曲程度等多特征进行跛行检测,相较于单一特征,能够显著提升检测的准确性。

4 结论

(1)提出了一种基于关键点检测和步行特征的猪只跛行检测方法,使用 YOLO v8n - pose 对猪只关键点进行检测,通过引入 RepGhost 网络和 BiFPN 双向特征金字塔结构,关键点检测的平均精度和召回率分别达到 92. 4% 和 87. 8%。相比 YOLO v8n - pose,mAP 和召回率分别提高 4. 2、0. 9 个百分点。将改进 YOLO v8n - pose 模型与其他经典关键点检测模型 (HRNet - w32、Lite - HRNet、ResNet50、ViPNAS 和 Hourglass) 进行对比,改进模型 mAP 分别高出 10. 2、11. 6、14. 2、11. 8、12. 5 个百分点。

(2)通过分析猪只关键点坐标和跛行特征,计算出猪只步行时的步长、膝盖角度和背部曲率 3 大特征,作为检测猪只是否跛行的依据。

(3)使用 K 最近邻 (KNN) 算法对猪只步行特征进行跛行检测,通过对 1 ~ 17 的 K 值逐一检验,最终确定 K 为 1 时准确率最高,为 81. 7%。与其他算法 (BP 算法、Decision Tree 算法和 SVM 算法) 对比,KNN 算法的准确率分别高出 1. 5、11. 3、6. 5 个百分点。

参 考 文 献

[1] ALA-KURIKKA E, HEINONEN M, MUSTONEN K, et al. Behavior changes associated with lameness in sows[J]. Applied Animal Behaviour Science, 2017, 193: 15 - 20.

[2] WILLGERT K J E, BREWSTER V, WRIGHT A J, et al. Risk factors of lameness in sows in England[J]. Preventive Veterinary Medicine, 2014, 113(2): 268 - 272.

[3] 李翠萍. 种猪跛行的危害及致跛常见病的诊治[J]. 饲料博览, 2021(2): 79 - 81.

LI Cuiping. Hazards of lameness in breeding pigs and diagnosis and treatment of common diseases causing lameness[J]. Feed Review, 2021(2): 79 - 81. (in Chinese)

- [4] 白会新, HEINONEN M, PELTONIEMI O, 等. 跛足和蹄损伤对母猪福利、健康和生产的影响[J]. 猪业科学, 2016, 33(2): 24–27.
BAI Huixin, HEINONEN M, PELTONIEMI O, et al. Impact of lameness and claw lesions in sows on welfare, health and production[J]. Pig Science, 2016, 33(2): 24–27. (in Chinese)
- [5] 全志民, 徐天哲, 石传森, 等. 基于 CBCW-YOLO v8 的猪只行为识别方法研究[J]. 农业机械学报, 2025, 56(2): 411–419.
TONG Zhimin, XU Tianzhe, SHI Chuanmiao, et al. Pig behavior recognition based on CBCW-YOLO v8 model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(2): 411–419. (in Chinese)
- [6] HERTEM T V, MALTZ E, ANTLER A, et al. Lameness detection based on multivariate continuous sensing of milk yield, rumination, and neck activity[J]. Journal of Dairy Science, 2013, 96(7): 4286–4298.
- [7] THORUP V M, DO NASCIMENTO O F, SKJØTH F, et al. Short communication: changes in gait symmetry in healthy and lame dairy cows based on 3-dimensional ground reaction force curves following claw trimming[J]. Journal of Dairy Science, 2014, 97(12): 7679–7684.
- [8] RHODIN M, BERGH A, GUSTÅS P, et al. Inertial sensor-based system for lameness detection in trotting dogs with induced lameness[J]. The Veterinary Journal, 2017, 222: 54–59.
- [9] PIETTE D, NORTON T, EXADAKTYLOS V, et al. Individualised automated lameness detection in dairy cows and the impact of historical window length on algorithm performance[J]. Animal, 2020, 14(2): 409–417.
- [10] 李前, 初梦苑, 康熙, 等. 基于计算机视觉的奶牛跛行识别技术研究进展[J]. 农业工程学报, 2022, 38(15): 159–169.
LI Qian, CHU Mengyuan, KANG Xi, et al. Research progress on lameness recognition technology in dairy cows using computer vision[J]. Transactions of the CSAE, 2022, 38(15): 159–169. (in Chinese)
- [11] JIANG B, SONG H, WANG H, et al. Dairy cow lameness detection using a back curvature feature[J]. Computers and Electronics in Agriculture, 2022, 194: 106729.
- [12] ZHENG Z, ZHANG X, QIN L, et al. Cows' legs tracking and lameness detection in dairy cattle using video analysis and Siamese neural networks[J]. Computers and Electronics in Agriculture, 2023, 205: 107618.
- [13] ZHAO K, ZHANG M, JI J, et al. Automatic lameness scoring of dairy cows based on the analysis of head- and back-hoof linkage features using machine learning methods[J]. Biosystems Engineering, 2023, 230: 424–441.
- [14] LI Q, HE Z, LIU X, et al. Lameness detection system for dairy cows based on instance segmentation[J]. Expert Systems with Applications, 2024, 249: 123775.
- [15] 康熙, 李树东, 张旭东, 等. 基于热红外视频的奶牛跛行运动特征提取与检测[J]. 农业工程学报, 2021, 37(23): 169–178.
KANG Xi, LI Shudong, ZHANG Xudong, et al. Features extraction and detection of cow lameness movement based on thermal infrared videos[J]. Transactions of the CSAE, 2021, 37(23): 169–178. (in Chinese)
- [16] 杜粤猛, 史慧, 高峰, 等. 基于姿态估计和关键点特征向量的奶牛跛行识别方法[J]. 华中农业大学学报, 2023, 42(5): 251–261.
DU Yueming, SHI Hui, GAO Feng, et al. A method for cow lameness recognition based on posture estimation and keypoints feature vector[J]. Journal of Huazhong Agricultural University, 2023, 42(5): 251–261. (in Chinese)
- [17] 王祥, 魏庆, 吴燕. 基于关键轮廓点模型的猪的步态异常检测[J]. 科技视界, 2019(12): 76–77, 85.
WANG Xiang, WEI Qing, WU Yan. Gait anomaly detection of pigs based on key contour point model[J]. Science and Technology Vision, 2019(12): 76–77, 85. (in Chinese)
- [18] 张站奇, 孙显彬, 孙贺, 等. 基于改进 YOLO v5-StrongSORT 的屠宰场猪只精准计数方法[J]. 农业机械学报, 2024, 55(12): 354–364.
ZHANG Zhanqi, SUN Xianbin, SUN He, et al. Accurate counting of pigs in slaughterhouses based on improved YOLO v5-StrongSORT[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(12): 354–364. (in Chinese)
- [19] 漆海霞, 冯发生, 尹选春, 等. 轻量级多场景群养猪只行为识别模型研究[J]. 农业机械学报, 2024, 55(10): 306–317.
QI Haixia, FENG Fasheng, YIN Xuanchun, et al. Research of lightweight multi-scene group pig behavior recognition model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(10): 306–317. (in Chinese)
- [20] 杨秋妹, 陈森彬, 黄一桂, 等. 基于改进 YOLO v5n 的猪只盘点算法[J]. 农业机械学报, 2023, 54(1): 251–262.
YANG Qiumei, CHEN Miaobin, HUANG Yigui, et al. Pig counting algorithm based on improved YOLO v5n[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(1): 251–262. (in Chinese)
- [21] FORSETH A K, KARRIKER L A, MILLMAN S T, et al. Validation of standing and locomotion scoring, behavioral assessments, and mechanical nociceptive threshold testing on naturally occurring sow lameness[J]. Animals, 2023, 13(11): 1801.
- [22] 王金鹏, 何萌, 甄乾广, 等. 基于改进 COF-YOLO v8n 的油茶果静态与动态检测计数方法[J]. 农业机械学报, 2024, 55(4): 193–203.
WANG Jinpeng, HE Meng, ZHEN Qianguang, et al. *Camellia oleifera* fruit static and dynamic detection counting based on improved COF-YOLO v8n[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(4): 193–203.

(in Chinese)

[23] PENG Y, PENG Z, ZOU H, et al. A dynamic individual yak heifer live body weight estimation method using the YOLOv8 network and body parameter detection algorithm[J]. Journal of Dairy Science, 2024, 107(8) : 6178 – 6191.

[24] 付辰伏, 任力生, 王芳, 等. 基于改进 YOLO v8 的牛只行为识别与跟踪方法[J]. 农业机械学报, 2023, 55(5) : 290 – 301. FU Chenfu, REN Lisheng, WANG Fang, et al. Method for cattle behavior recognition and tracking based on improved YOLO v8[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 55(5) : 290 – 301. (in Chinese)

[25] TAN M, PANG R, LE Q V. EfficientDet: scalable and efficient object detection[J]. arXiv Preprint, arXiv: 1911.09070, 2019.

[26] XU W, CUI C, JI Y, et al. YOLOv8 – MPEB small target detection algorithm based on UAV images[J]. Heliyon, 2024, 10(8) : e29501.

[27] FENG X, GAO X, LUO L. A ResNet50-based method for classifying surface defects in hot-rolled strip steel[J]. Mathematics, 2021, 9(19) : 2359.

[28] HAN K, WANG Y, TIAN Q, et al. GhostNet: more features from cheap operations[J]. arXiv Preprint, arXiv: 1911.11907, 2020.

[29] CHEN C, GUO Z, ZENG H, et al. RepGhost: a hardware-efficient ghost module via re-parameterization[J]. arXiv Preprint, arXiv: 2211.06088, 2022.

[30] SUN K, XIAO B, LIU D, et al. Deep high-resolution representation learning for human pose estimation[J]. arXiv Preprint, arXiv: 1902.09212, 2019.

[31] YU C, XIAO B, GAO C, et al. Lite – HRNet: a lightweight high-resolution network[J]. arXiv Preprint, arXiv: 2104.06403, 2021.

[32] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[J]. arXiv Preprint, arXiv: 1512.03385, 2015.

[33] XU L, GUAN Y, JIN S, et al. ViPNAS: efficient video pose estimation via neural architecture search[J]. arXiv Preprint, arXiv: 2105.10154, 2021.

[34] NEWELL A, YANG K, DENG J. Stacked hourglass networks for human pose estimation[J]. arXiv Preprint, arXiv: 1603.06937, 2016.

[35] 彭兆东, 涂琦玉, 彭烨超. 基于 Canny 边缘检测的空频结合图像增强算法[J]. 工业控制计算机, 2024, 37(4) : 106 – 108. PENG Zhaodong, TU Qiyu, PENG Yechao. Spatial frequency combined image enhancement algorithm based on Canny edge detection[J]. Industrial Control Computer, 2024, 37(4) : 106 – 108. (in Chinese)