



尹朝阳,叶俊华,徐爱俊,等. 基于骨架特征的生猪行为识别方法[J]. 南京农业大学学报,2026,49(3):708-718.

Yin Z Y, Ye J H, Xu A J, et al. Pig behavior recognition method based on skeleton features[J]. Journal of Nanjing Agricultural University, 2026,49(3): 708-718.

基于骨架特征的生猪行为识别方法

尹朝阳¹, 叶俊华², 徐爱俊^{1,3*}, 周素茵¹, 梁梓源¹

(1.浙江农林大学数学与计算机科学学院,浙江杭州 311300;2.浙江农林大学环境与资源学院,浙江 杭州 311300;
3.全省农业智能感知与机器人重点实验室,浙江 杭州 311300)

摘要:[目的]生猪健康状况与其行为密切相关,而生猪行为与其骨架特征直接关联,本文提出了一种基于骨架特征的生猪行为识别方法。[方法]使用 YOLOv8s-Pose 算法检测生猪关键点,提取生猪骨架特征,并将其输入图卷积网络,在图卷积网络中引入残差结构,以加速模型的训练和优化过程,再引入一种加权策略,对不同位置的关键点信息进行距离加权,在保留远邻节点信息的同时,增强了近邻节点的特征表达,提升了模型的行为识别性能。[结果]模型对生猪站、坐、躺 3 种行为识别的平均精确率达到了 87.30%,相比 YOLOv8s 模型提高了 6.53 百分点,同时 100 次推理时间仅有 0.19 s。[结论]提出的生猪行为识别方法能实现生猪日常行为的准确、快速分类,为群养生猪日常行为监测和健康评估提供了技术参考。

关键词:猪;行为识别;姿态估计;图卷积网络;关键点检测

中图分类号:S828

文献标志码:A

文章编号:1000-2030(2026)03-0708-11

Pig behavior recognition method based on skeleton features

YIN Zhaoyang¹, YE Junhua², XU Aijun^{1,3*}, ZHOU Suyin¹, LIANG Ziyuan¹

(1.School of Mathematics and Computer Science,Zhejiang A&F University, Hangzhou 311300, China;

2.School of Environmental and Resource Science,Zhejiang A&F University, Hangzhou 311300, China;

3.Zhejiang Key Laboratory of Intelligent Sensing and Robotics for Agriculture, Hangzhou 311300, China)

Abstract: [Objectives] The health status of live pigs is closely related to their behavior, and their behavior is directly related to their skeletal features. Therefore, a pig behavior recognition method based on skeletal features was proposed in this paper. [Methods] The YOLOv8s-Pose algorithm was used to detect key points of pigs and extract skeleton features of pigs, and then input the features into a graph convolutional network; residual structures were introduced into graph convolutional networks to accelerate the training and optimization process of the model; a weighting strategy was introduced to weight the distance of keypoint information at different locations, which further enhanced the feature expression of neighboring nodes while retaining the information of distant nodes, thereby improving the behavior recognition performance of the model. [Results] The experimental results showed that the model achieved an average accuracy of 87.30% in recognizing the behaviors of pigs standing, sitting, and lying, which was 6.53 percentage points higher than the YOLOv8s model. At the same time, the inference time for 100 times was only 0.19 seconds. [Conclusions] The pig behavior recognition method proposed in this article could achieve accurate and rapid classification of daily pig behavior, providing technical reference for monitoring and health assessment of group pigs' daily behavior.

Keywords: pig; behavior recognition; pose estimation; graph convolutional network; keypoint detection

生猪健康状况与其行为息息相关,随着生猪养殖场向规模化、智能化方向发展,识别生猪行为实时监测其健康状况逐渐成为生产过程中的重要需求^[1-2]。传统的饲养员人工监测生猪行为的方式存在主观性强、效率低的问题^[3-4],而借助传感器或人工智能技术可以实现高效、低成本且无干扰的生猪行为监测。

目前,国内外针对生猪行为识别的研究主要包括基于传感器的识别方法和基于计算机视觉的深度学习方法。在基于传感器技术的生猪行为识别研究中,闫丽等^[5]使用加速度传感器持续监测哺乳母猪行为,分析其哺乳姿态,了解其哺乳意愿。刘龙申等^[6]设计了一种基于三轴加速度传感器和无线传感网络的母猪产前行为特征监测系统,实现了对母猪典型行为的分类。潘芷欣等^[7]将姿态传感器分别固定在母猪的耳根和后腿,采用时域特征提取方法和随机森林算法构建了母猪产后行为识别模型,实现了体动、进

收稿日期:2024-11-23

基金项目:浙江省“领雁”研发攻关计划项目(2022C02050)

*通信作者:徐爱俊,博士,教授,主要从事计算机技术和GIS在农业中的应用研究,E-mail:xuaj1976@163.com。

食、哺乳等6种产后行为的识别。这些基于传感器的生猪行为识别方法虽然准确度较高,但因存在易脱落、易损坏、成本较高以及可能干扰生猪正常活动等问题而受到限制^[8]。机器视觉和深度学习技术的迅速发展,使得群猪行为的自动持续监测成为可能^[9]。杨秋妹等^[10]利用深度学习检测生猪头部,并提出了一种结合阈值分割、图像占领指数计算的行为识别方法,能够自动识别生猪的饮水行为。查文文等^[11]将改进的YOLOv5S模型与DeepSORT算法相结合识别生猪个体行为,实现了在嵌入式边缘计算节点上的高效多目标识别与跟踪,FPS达到了 $21.7 \text{ f}\cdot\text{s}^{-1}$ 。Alameer等^[12]设计了一种基于视觉的深度学习算法,无需额外的标记就能有效区分生猪饮食行为和非饮食性访问(NNV)并自动记录,精确率高达99.4%。Yang等^[13]通过计算生猪头部和饮食槽的IoU识别生猪是否处于饮食状态。李艳文等^[14]通过改进的Yolox算法识别生猪攻击行为,并引入了攻击活动比例和攻击行为比例2个指标对生猪攻击行为进一步量化。基于深度学习的生猪行为识别方法能够对低维特征进行抽象和建模,提取出更具代表性的特征,满足了复杂环境下生猪行为识别的需求^[15-17]。在基于深度学习的生猪行为识别方法研究中,图卷积网络也表现出了显著的应用潜力。董力中等^[18]结合YOLOv5、OpenPose以及ST-GCN构建了一个生猪行为识别系统,能够识别生猪站、走、躺3种行为,平均精确度达到了86.67%。李光昌等^[19]设计了一种基于改进OpenPose算法的生猪行为识别方法,通过提取生猪的骨骼关键点并结合K-最近邻算法实现了高精度的生猪行为分类。Gan等^[20]通过构建包含节点信息的时空图量化仔猪的交互行为,成功识别出了仔猪的鼻子接触和攻击行为,精确度高达96.69%。陆舟等^[21]通过替换骨干网络、结合SE注意力机制等方法改进YOLOv5L,能够在复杂养殖环境中全天候识别育肥猪采食行为。

相对于生猪外观特征,其骨架特征即关键点信息具有如下优势:1)关键点直接关联生猪的行为,具有高度解释性;2)关键点表示关节和肢体的相对位置与运动模式,独立于个体外观特征,有利于模型的泛化;3)关键点检测受光线变化、非严重遮挡及背景复杂度的影响相对较小,从而提高了模型的鲁棒性。因此,本文提出了基于骨架特征的生猪行为识别方法:先提取生猪骨架关键点并将其输入图卷积网络,并在图卷积网络中引入残差结构加速模型训练和优化;最后,引入加权策略,对骨架特征信息进行距离加权,提升模型性能,以实现生猪站、坐、躺3种行为的准确分类。

1 数据集构建

1.1 姿态估计数据集

生猪视频来源于Wang等^[22]提供的数据集,该数据集包含了俯视和侧视视角下的视频。由于俯视视角下猪蹄、肘部关键点容易被身体遮挡,难以标注,因此本研究均使用侧视视角下的数据。共选取了6段侧视视频用于生猪姿态估计,图像示例如图1所示。将生猪骨架分为头部、背部、尾部和四肢4部分进行标注,共14个关键点。标注方式和关键点的连接方式分别如图2和表1所示。在原数据集基础上,额外标注了829张图像用于姿态估计,形成了1个包含2020张标注图像的原始数据集,按8:2比例划分为训练集和测试集。为提高模型的泛化能力,使用Python的Imgaug数据增强库的椒盐噪声、高斯模



图1 在猪栏不同方位拍摄的生猪侧视图像示例

Fig. 1 Examples of side-view images of live pigs taken from different positions around the pig pen

糊、调整亮度、调整饱和度、水平翻转等多种方式对图像进行增强,确保模型在光线不佳、环境复杂的猪舍环境下具有良好的骨架提取效果。增广后的数据集共计 8 080 张。

1.2 生猪行为数据集

对姿态估计数据集进行行为标注后得到生猪行为数据集,共包含 2 394 个样本,其中站、躺和坐的样本分别为 1 222、845 和 327。3 种行为的定义^[23]与标注分别如表 1 和图 3 所示。为避免图像中因喂食槽、饮水器等遮挡造成的不完整数据对模型产生影响,标注时首先将身体可见范围低于 60% 的生猪图像剔除,再对其他猪只进行标注,并保存为 csv 文件。此外,为应对实际应用场景中关键点可能误检和漏检的情况,对数据同时采用了以下 2 种数据增强方式:1)随机对样本移除 1~3 个关键点;2)随机对 1~3 个关键点移动 0~8 个像素。

利用上述方法,将数据泛化 2 倍,共 7 182 个样本。为避免样本失衡,随机丢弃多余样本,使每个类别的样本数量对齐至最少类别数,最终每个类别保留了 783 个样本。训练集和测试集按 8:2 比例划分。




图 2 生猪骨架关键点标注示意图
Fig. 2 Schematic diagram of key point annotation for pig skeleton

- 1.鼻部 Nose;2.头部 Head;3.肩部 Shoulder;
4.背脊中心 Backbone;5.髋部 Hip;6.尾部 Tail;
7.前左肘 Front left elbow;8.前左蹄 Front left hoof;9.前右肘 Front right elbow;10. 前右蹄 Front right hoof;11. 后左肘 Hind left elbow;12. 后左蹄 Hind left hoof;13. 后右肘 Hind right elbow;14. 后右蹄 Hind right hoof.

表 1 生猪行为定义
Table 1 Definition of pig behavior

行为 Behavior	行为描述 Behavior description
站 Stand	前后腿均接触地面,身体直立,与地面保持一定距离 Both forelegs and hind legs are in contact with the ground,and the body remains upright.
坐 Sit	前腿直立,后腿折叠,尾巴接触地面 The forelegs are straight,the hind legs are folded,and the tail touches the ground.
躺 Lie	身体一侧接触地面,腹部和腿部暴露在外;或腹部接触地面,前腿折叠于身体下方 One side of the body or the abdomen is in contact with the ground,with the forelegs folded beneath the body.




图 3 生猪行为标注
Fig. 3 Pig behavior annotation

2 生猪行为识别方法

利用 YOLOv8s-Pose 模型对输入的视频进行姿态估计,提取生猪骨架关键点,再将关键点数据输入图卷积网络(GCN)提取特征完成行为识别。识别流程如图 4 所示。图卷积网络采用了残差结构以增强模型的特征流动,提升模型的训练效率和收敛速度,并设计了关键点特征加权策略以突出重要关键点,通过提升重要关键点的权重提高行为识别的准确性。




图 4 生猪行为识别方法整体流程

Fig. 4 Overall process of pig behavior recognition method

2.1 姿态估计

姿态估计是通过检测图像或视频中的目标关键点实现姿态识别的关键技术,选用人体姿态估计模型 YOLOv8s-Pose 估计生猪姿态。YOLOv8s-Pose 的网络结构如图 5 所示。YOLOv8s-Pose 以 YOLOv8s 为基础,在增加卷积层的基础上设计了 C2F 模块,增强了特征连通性和网络表达能力;采用 Anchor-Free 设计简化了超参数调整,提升了训练与推理效率;通过回归的方式来预测每个关键点的坐标和置信度,简化训练流程提高推理速度;采用 DFL Loss 作为损失函数,并使用 TaskAlignedAssigner 作为正样本匹配策略,提高模型检测精度和收敛速度。




图 5 YOLOv8s-Pose 网络结构图

Fig. 5 YOLOv8s-Pose network structure diagram

2.2 行为识别

2.2.1 图卷积网络 在 GCN 中,将数据表示为 1 个图,图中节点代表实体(如生猪骨架关键点),边代表节点之间的关系或连接(如骨架关键点的连接关系)。对于 1 个图, $G=(V,E)$ 。式中: V 表示节点的集合; E 为节点之间的连接或边的集合。图的连接性通过邻接矩阵 A 描述,矩阵的每个元素 A_{ij} 表示节点 i 和节点 j 之间是否存在直接的连接关系。通常情况下,邻接矩阵是一个 $|V| \times |V|$ 的方阵,其规模由图中节点的数量决定。GCN 通过在图结构数据上进行卷积,能在学习节点表示的同时,保留节点之外的拓扑结构信

息,因此更适用于解决图相关问题。

图卷积网络操作表示如下:

$$H^{l+1} = \sigma(\hat{D}^{-\frac{1}{2}} \hat{A} \hat{D}^{-\frac{1}{2}} H^l W^l) \quad (1)$$

式中: $\hat{A}$ 为邻接矩阵 A 加上单位矩阵; $\hat{D}$ 是 $\hat{A}$ 的度矩阵的对角矩阵; H^l 是第 l 层的节点特征; W^l 是第 l 层的权重矩阵; σ 是激活函数。图卷积网络结构如图6所示。




图6 图卷积网络结构

Fig. 6 Graphical convolutional network structure

2.2.2 拓展到图卷积网络的卷积操作 为适应图数据节点之间连接结构存在的非规则性和可变性,本研究在GCN中引入了一种基础卷积块^[24]。该卷积块通过聚合邻域节点特征,并结合邻接矩阵信息,实现了对复杂图结构的卷积操作,有效捕捉了节点间的局部关系。基础卷积块的标准卷积操作描述:给定一个核大小为 $K \times K$ 的卷积算子和1个具有 c 个通道的输入特征图 f_{in} ,在空间位置 x 处的单通道输出值通过聚合 x 周围 $K \times K$ 邻域的信息进行计算。输出值 $f_{out}(x)$ 的计算公式:

$$f_{out}(x) = \sum_{h=1}^K \sum_{w=1}^K f_{in}(s(x, h, w)) \cdot \theta(h, w) \quad (2)$$

式中:采样函数 $s: Z^2 \times Z^2 \rightarrow Z^2$ 枚举了位置 x 的邻居,即确定输入特征图中位置 x 周围的 $K \times K$ 区域的每个邻居位置;权重函数 $\theta: Z^2 \rightarrow R^2$ 为每个卷积核位置提供了1个 c 维空间中的权重向量,用于与采样到的 c 维输入特征向量进行内积计算。

标准卷积操作针对每个节点的直接邻居进行采样并将其作为采样结果,同时通过固定数量的分区标记邻居节点,确保每次采样数量的一致性,并根据节点所在分区进行加权,从而维持加权顺序的一致性。

2.2.3 残差结构 在图卷积网络中,卷积操作的主要作用是对节点的邻接信息进行特征聚合,但随着网络深度的增加,模型存在过拟合问题。因此,本研究在图卷积网络中引入了残差结构^[25],通过直接跨层连接将输入添加到输出上,不仅能缓解过拟合,还能加速模型的训练和优化,提升模型的性能和稳定性。

2.2.4 距离加权 为应对图卷积网络中节点间连接的不规则性和变异性,使用距离加权进行特征聚合。距离加权是一种基于距离的加权方法,即根据邻居节点与根节点之间的距离确定节点权重,距离越近的节点权重越大,反之越小。本方法采用固定数量的分区标记根节点周围的邻居节点,根据邻居节点到根节点的距离,为邻居节点分配权重,距离越近,权重越高,权重计算公式如式(3)所示。

$$weight_{ij} = \exp(-\|p_i - p_j\|) \quad (3)$$

式中: $weight_{ij}$ 是节点 i 和 j 之间的权重; $\|p_i - p_j\|$ 是节点 i 和 j 之间的欧氏距离。将式(3)代入式(2),可得:

$$f_{out}(v_i) = \sum_{v_j \in B(v_i)} \left(\frac{1}{Z_i(v_j)} f_{in}(s(v_i, v_j)) \cdot \exp(-\|p_i - p_j\|) \right) \quad (4)$$

式中, $Z_i(v_j)$ 是归一化因子。

距离加权强调了近邻节点对根节点特征的重要性,同时保留了远邻节点的信息,增强了特征表示的鲁棒性。图7为距离加权示例,图中点的大小代表该节点的权重大小。




图7 以2个结点为例的距离加权示意图

Fig. 7 Schematic diagram of distance weighting using two nodes as an example

3 模型训练环境与评价指标

试验均在操作系统 Ubuntu23.04、CPU 型号为 Intel i7-13700KF、显卡为具有 24 G 显存的 NVIDIA GeForce RTX 3090Ti 的服务器上进行。使用的 Python 版本为 3.8.0,深度学习框架 Pytorch 版本为 1.13.1。YOLOv8s-Pose 将 Batch size 设置为 32,模型输入尺寸为 640×640 ,训练 200 个 Epoch。图卷积模型使用 RMSprop 优化器,学习率与 L2 正则项为 0.001,训练 1 000 个 Epoch。

使用精确率 (Precision) 对生猪行为识别模型进行性能评价,其计算如式(5)所示。关键点精度评价使用 OKS 指标,其定义如式(6)所示。

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

$$OKS = \frac{\sum_i \exp(-d_i^2/2s^2 \cdot k_i^2) \cdot \delta(v_i > 0)}{(\sum_i [\delta(v_i > 0)])} \quad (6)$$

式中: TP 表示样本为正确且推理结果也为正确的数量; FP 表示推理结果与真实结果不符的数量。 d_i 是预测关键点与真实关键点之间的欧几里得距离; s 代表目标的尺度(目标为猪); k_i 是关键点 i 的一个常数,用于控制关键点的重要性; v_i 是关键点 i 的可见性标签; δ 是指示函数,当 $v_i > 0$ 时, δ 为 1,否则为 0。

除上述指标外,还引入了浮点运算次数 GFLOPS 和参数量 Params 2 个指标,分别用于评估模型的计算效率和衡量模型的复杂度及资源需求。

4 结果与分析

4.1 姿态估计结果分析与比较

为深入评估 YOLOv8s-Pose 在关键点检测任务中的表现,将其与几种经典的姿态估计模型进行性能比较,所有模型均使用数据集重新训练。结果如表 2 所示, AP50、AP75 和 AP90 是根据 OKS 评分计算得到的。YOLOv8s-Pose 的整体性能较好,尤其是在高精度阈值(AP90)方面表现突出。

表2 姿态估计模型性能比较

Table 2 Performance comparison of attitude estimation models

模型 Method	骨干网络 Backbone	精度(阈值 50) AP50	精度(阈值 75) AP75	精度(阈值 90) AP90	浮点运算 GFLOPS	参数量 Params
Deeplabcut ^[26]	ResNet	82.2	43.9	32.1	3.80	25.60
AlphaPose ^[27]	ResNet	83.9	60.0	19.2	12.80	5.17
YOLOv7-Pose ^[28]	YOLO	81.2	47.6	18.3	9.20	3.30
YOLOv11s-Pose	YOLO	83.7	56.9	34.2	23.20	9.90
Hrnet-w32 ^[29]	Hrnet	81.1	44.1	21.0	28.54	7.70
RtmPose-m ^[30]	CSPNeXt	75.9	18.5	6.6	2.54	13.51
SimCC ^[31]	MobileNetV2	71.9	19.0	9.9	0.31	2.29
YOLOv8s-Pose	YOLO	83.2	57.9	36.4	30.20	11.60

为直观展示本模型在姿态评价中的优势,3 种姿态估计模型的对比结果见图 8。在相同场景下, YOLOv8s-Pose 的骨架提取效果略好于 YOLOv11-Pose,但明显优于 AlphaPose。图 8 上图中, YOLOv8s-Pose 和 YOLOv11-Pose 的效果接近,但 YOLOv8s-Pose 的置信度明显高于 YOLOv11-Pose,而 AlphaPose 的骨架提取结果中分别存在蹄部关键点检测错误和关键点错乱的问题。图 8 中图中, YOLOv11-Pose 提取的蹄部关键点位置均不正确, AlphaPose 则是头部关键点提取错误。图 8 下图图中,相比 YOLOv8s-Pose 和 YOLOv11-Pose, AlphaPose 的关键点提取效果较差。




图 8 姿态估计模型对比

Fig. 8 Comparison of pose estimation models

黄框为检测存在错误的猪只。Yellow boxes indicate pigs with detection errors.

尽管 YOLOv8s-Pose 模型取得了好的姿态估计效果,但依然存在漏检和误检的问题。这主要是由于现有的检测器尚未达到理想的性能,无法在复杂场景下准确识别生猪。生猪关键点缺失和姿态被遮挡情况下的检测结果见图 9。虽然这些情况对关键点提取效果有影响,但在训练图卷积网络时已经考虑了关键点可能缺失的情况,少量的关键点错误或丢失并不会显著影响模型的整体输出结果。



图 9 姿态估计错误示例

Fig. 9 The results of the attitude estimation error

黄框为检测存在错误的猪只。Yellow boxes indicate pigs with detection errors.

4.2 行为识别结果分析与比较

为深入评估本方法对生猪站、坐、躺 3 种行为的分类效果,将其与常见的几种姿态分类模型进行比较,结果如表 3 所示。其中,ST-GCN 训练的时间窗口设置为 1。由表 3 可知:相比于其他模型,图卷积网络方法对于站、躺、坐 3 种行为的分类效果更好。在 3 种行为中,躺的识别精确度最低,仅为 74.5%,该现象在 YOLOv8s、YOLOv7w6 等模型结果中也有体现,这可能归因于躺卧姿态分为 2 种,且与站姿较难区分。相比之下,深度学习方法的效果普遍优于机器学习方法,但 XGBoost 模型取得了较好的效果,从侧面说明利用骨架特征分析行为是可行的。

表 3 不同行为识别的精确度

Table 3 Precision of different behavior recognition results

%

模型 Model	精确度 Precision			平均精确度 Average precision
	站 Stand	躺 Lie	坐 Sit	
YOLOv8s	83.6	76.7	81.9	80.7
YOLOv7w6 ^[28]	77.1	67.7	68.1	71.0
MLP ^[32]	89.2	53.1	51.6	64.6
XGBoost ^[33]	83.5	76.2	60.0	73.2
ST-GCN	88.4	72.6	83.4	81.5
本模型 This model	93.2	74.5	94.1	87.2

不同视角下生猪行为识别的效果见图 10。尽管生猪存在一定的互相遮挡,但模型依旧能够准确地识别其行为。



图 10 不同视角下的生猪行为识别结果

Fig. 10 Behavior recognition results of pigs from different perspectives

4.3 图卷积网络深度对分类准确性的影响

为探究图卷积网络的深度对行为分类的影响,分别验证了 2、3 和 4 层图卷积网络在分类任务中的性能,结果见表 4。推理速度为分类模型推理 100 次所用的平均时间。由表 4 可知:不同层次的图卷积网络效果各异。2 层网络效果最差,可能是因为较简单的结构难以捕捉到图数据中复杂的特征,从而限制了模型的表达能力和分类性能;3 层网络最为均衡,尽管对躺行为的识别精确率较低,但平均精确率最高;5 层网络对生猪躺行为的识别效果最好,可能由于更深的网络结构有助于提取更抽象和更细致的特征,从而更符合复杂行为的识别需求,但对相对简单的行为识别精确率却有所下降。综上,本研究选择了综合性能最佳的 3 层网络作为试验模型。

表 4 不同层数图卷积的行为分类结果

Table 4 Behavior classification results of graph convolution with different layers

层数 Layers	精确率/% Precision			平均精确率/% Average precision	推理速度/s Inference speed
	站 Stand	躺 Lie	坐 Sit		
2	70.8	74.5	82.4	75.9	0.10
3	93.2	74.5	94.1	87.3	0.19
4	86.5	78.4	91.2	85.4	0.27
5	83.2	90.2	71.8	81.7	0.28

4.4 消融试验

为探究不同模型结构、距离加权以及数据增强对行为识别效果的影响,进行了消融试验。结果如表 5

所示:试验 8 未使用图数据增强,试验样本数量不平衡,通过调整类别权重提升模型对少数类别的关注。仅使用图卷积或残差结构均能在一定程度上提高模型的识别精确率,这表明拓展图卷积能够通过更换卷积核增强模型的特征抽取能力,从而更有效地提取关键点的特征,而残差结构有助于缓解模型中的特征信息衰减问题,这使得特征能够更有效地传递,当拓展图卷积与残差结构协同使用时,模型对生猪各行为类别的识别精度均显著提高。仅使用距离加权策略时,模型的平均精确率仅提高了 0.5 百分点,而将其与拓展图卷积模型组合使用时平均精度提高了 3.4 百分点,这表明拓展图卷积能够有效补足距离加权策略对全局语义关联的捕捉不足。当 3 种策略组合使用时,模型的平均精确率提高了 7.3 百分点,这表明 3 种策略组合既能提升模型的特征提取能力,还能缓解训练中的特征信息衰减。当 3 种策略与图数据增强结合使用时,模型的识别精确率提高了 0.9 百分点,这说明实际使用时检测器存在一定误差,而图数据增强在一定程度上提升了模型的鲁棒性。

表 5 消融试验
Table 5 Ablation experiment

试验 Experiment	拓展图卷积 Extended graph convolution	残差结构 Residual structure	距离加权 Distance weighting	图数据增强 Graph data augmentation	精确率/%Precision			平均精确率/% Average precision
					站 Stand	躺 Lie	坐 Sit	
1				√	85.3	69.8	82.1	79.1
2	√			√	87.4	72.6	84.2	81.4
3			√	√	85.6	71.4	81.9	79.6
4		√		√	86.1	70.6	82.8	79.8
5	√		√	√	88.9	72.2	86.5	82.5
6	√	√		√	91.6	73.0	91.8	85.5
7		√	√	√	84.0	72.0	83.1	79.7
8	√	√	√		92.1	73.8	93.4	86.4
9	√	√	√	√	93.2	74.5	94.1	87.3

5 结论

本文提出了一种基于骨架特征的生猪行为识别方法,利用图卷积网络实现了对生猪站、躺和坐 3 种行为较准确的分类。

1)通过对生猪图像的采集、标注和泛化,构建了一个囊括生猪目标检测、关键点提取和行为识别的数据集。此外,还构建了一个用于生猪行为分类的图数据集,并针对实际场景中关键点可能误检、漏检的情况设计了图数据增强方法。

2)使用 YOLOv8s-Pose 估计生猪姿态,其 AP50 达到了 83%。在目标检测和姿态估计任务中,YOLOv8s-Pose 的综合性能优于 Deeplabcut、Alphapose 和 YOLOv7w6-Pose 等经典模型。

3)构建的图卷积网络行为识别模型对站、躺、坐 3 种行为的平均识别精确率达到了 87.3%,其中坐姿识别精确率高达 94.1%,该模型在行为识别任务中的总体表现优于 YOLOv8s、YOLOv7w6、XGBoost 和 MLP 方法。

未来的研究可以进一步提升检测器在复杂场景下的准确性,进而提升行为识别的准确性。

参考文献 References:

[1] 何东健,刘冬,赵凯旋. 精准畜牧业中动物信息智能感知与行为检测研究进展[J]. 农业机械学报,2016,47(5):231-244.
He D J,Liu D,Zhao K X. Review of perceiving animal information and behavior in precision livestock farming[J]. Transactions of the Chinese Society for Agricultural Machinery,2016,47(5):231-244(in Chinese with English abstract).

[2] 闫丽,邵庆,席桂清. 家畜行为智能监测系统的研究进展[J]. 家畜生态学报,2014,35(12):6-10.
Yan L,Shao Q,Xi G Q. Research progress of livestock behavior intelligent monitoring system[J]. Acta Ecologiae Animalis Domastici,2014,35(12):6-10(in Chinese with English abstract).

[3] Iredale S K,Nevill C H,Lutz C K. The influence of observer presence on baboon (*Papio* spp.) and Rhesus macaque (*Macaca mulatta*) behavior [J]. Applied Animal Behaviour Science,2010,122(1):53-57.

[4] 缪晓辉. 浅谈生猪规模养殖存在的问题和对策[J]. 中国动物保健,2021,23(11):80-81.
Miao X H. Discussion on the problems and countermeasures of large-scale pig breeding[J]. China Animal Health,2021,23(11):80-81 (in Chinese).

[5] 闫丽,沈明霞,姚文,等. 基于 MPU6050 传感器的哺乳期母猪姿态识别方法[J]. 农业机械学报,2015,46(5):279-285.

- Yan L, Shen M X, Yao W, et al. Recognition method of lactating sows' posture based on sensor MPU6050[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(5): 279-285 (in Chinese with English abstract).
- [6] 刘龙申, 沈明霞, 姚文, 等. 基于加速度传感器的母猪产前行为特征采集与分析[J]. 农业机械学报, 2013, 44(3): 192-196, 191.
Liu L S, Shen M X, Yao W, et al. Acquisition and analysis of sows' behavior before farrowing based on acceleration sensor[J]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(3): 192-196, 191 (in Chinese with English abstract).
- [7] 潘芷欣, 陈荟慧, 钟委钊. 基于可穿戴设备的母猪产后行为识别[J]. 农业工程学报, 2022, 38(增刊1): 209-217.
Pan Z X, Chen H H, Zhong W Z. Recognition of the behaviour of lactating sows using wearable devices[J]. Transactions of the Chinese Society of Agricultural Engineering, 2022, 38(Suppl 1): 209-217 (in Chinese with English abstract).
- [8] 刘龙申, 柳桢, 周杰, 等. 母猪精准养殖智能感知技术研究进展[J]. 华南农业大学学报, 2024, 45(5): 635-648.
Liu L S, Liu L, Zhou J, et al. Research progress on precision breeding and intelligent sensing technologies for sows[J]. Journal of South China Agricultural University, 2024, 45(5): 635-648 (in Chinese with English abstract).
- [9] 贺稚非, 余思洁, 李洪军, 等. 非洲猪瘟病毒生物学特性及在猪肉生产中的防控措施研究[J]. 农业工程学报, 2019, 35(10): 299-304.
He Z F, Yu S J, Li H J, et al. Biological characteristics of African swine fever virus and its prevention and control measures in pork food production[J]. Transactions of the Chinese Society of Agricultural Engineering, 2019, 35(10): 299-304 (in Chinese with English abstract).
- [10] 杨秋妹, 肖德琴, 张根兴. 猪只饮水行为机器视觉自动识别[J]. 农业机械学报, 2018, 49(6): 232-238.
Yang Q M, Xiao D Q, Zhang G X. Automatic pig drinking behavior recognition with machine vision[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(6): 232-238 (in Chinese with English abstract).
- [11] 查文文, 潘伟豪, 陈成鹏, 等. 基于边缘计算与改进 YOLOv5 的群养生猪姿态识别及跟踪研究[J]. 东北农业大学学报, 2023, 54(3): 83-96.
Zha W W, Pan W H, Chen C P, et al. Study on pose recognition and tracking of herd-raised pigs based on edge computing and improved YOLOv5[J]. Journal of Northeast Agricultural University, 2023, 54(3): 83-96 (in Chinese with English abstract).
- [12] Alameer A, Kyriazakis I, Dalton H A, et al. Automatic recognition of feeding and foraging behaviour in pigs using deep learning[J]. Biosystems Engineering, 2020, 197: 91-104.
- [13] Yang Q M, Xiao D Q, Lin S C. Feeding behavior recognition for group-housed pigs with the Faster R-CNN[J]. Computers and Electronics in Agriculture, 2018, 155: 453-460.
- [14] 李艳文, 李菊霞, 纳腾藩, 等. 基于 YOLOX-NGS 的群养猪只攻击行为识别[J]. 农业工程学报, 2023, 39(24): 177-184.
Li Y W, Li J X, Na T X, et al. Recognizing attack behavior of herd pigs using improved YOLOX[J]. Transactions of the Chinese Society of Agricultural Engineering, 2023, 39(24): 177-184 (in Chinese with English abstract).
- [15] 房俊龙, 胡宇航, 戴百生, 等. 采用改进 CenterNet 模型检测群养生猪目标[J]. 农业工程学报, 2021, 37(16): 136-144.
Fang J L, Hu Y H, Dai B S, et al. Detection of group-housed pigs based on improved CenterNet model[J]. Transactions of the Chinese Society of Agricultural Engineering, 2021, 37(16): 136-144 (in Chinese with English abstract).
- [16] 肖德琴, 冯爱晶, 杨秋妹, 等. 基于视频追踪的猪只运动快速检测方法[J]. 农业机械学报, 2016, 47(10): 351-357, 331.
Xiao D Q, Feng A J, Yang Q M, et al. Fast motion detection for pigs based on video tracking[J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(10): 351-357, 331 (in Chinese with English abstract).
- [17] 高云, 陈斌, 廖慧敏, 等. 群养猪侵略性行为的深度学习识别方法[J]. 农业工程学报, 2019, 35(23): 192-200.
Gao Y, Chen B, Liao H M, et al. Recognition method for aggressive behavior of group pigs based on deep learning[J]. Transactions of the Chinese Society of Agricultural Engineering, 2019, 35(23): 192-200 (in Chinese with English abstract).
- [18] 董力中, 孟祥宝, 潘明, 等. 基于姿态与时序特征的猪只行为识别方法[J]. 农业工程学报, 2022, 38(5): 148-157.
Dong L Z, Meng X B, Pan M, et al. Recognizing pig behavior on posture and temporal features using computer vision[J]. Transactions of the Chinese Society of Agricultural Engineering, 2022, 38(5): 148-157 (in Chinese with English abstract).
- [19] 李光昌, 刘飞飞, 李嘉豪. 基于改进 OpenPose 算法的猪只行为识别方法[J]. 河南农业大学学报, 2022, 56(3): 460-470.
Li G C, Liu F F, Li J H. Pig behavior recognition method based on improved OpenPose algorithm[J]. Journal of Henan Agricultural University, 2022, 56(3): 460-470 (in Chinese with English abstract).
- [20] Gan H M, Xu C G, Hou W H, et al. Spatiotemporal graph convolutional network for automated detection and analysis of social behaviours among pre-weaning piglets[J]. Biosystems Engineering, 2022, 217: 102-114.
- [21] 陆舟, 沈明霞, 刘龙申, 等. 基于轻量化网络与注意力机制的育肥猪采食行为识别方法研究[J]. 南京农业大学学报, 2023, 46(4): 802-812. DOI: 10.7685/jnau.202208023.
Lu Z, Shen M X, Liu L S, et al. Study on feeding behavior recognition method of fattening pigs based on lightweight networks and attention mechanism[J]. Journal of Nanjing Agricultural University, 2023, 46(4): 802-812 (in Chinese with English abstract).
- [22] Wang Z H, Zhou S Y, Yin P, et al. GANPose: Pose estimation of grouped pigs using a generative adversarial network[J]. Computers and Electronics in Agriculture, 2023, 212: 108119.
- [23] Yang Q M, Xiao D Q. A review of video-based pig behavior recognition[J]. Applied Animal Behaviour Science, 2020, 233: 105146.
- [24] Yan S J, Xiong Y J, Lin D H. Spatial temporal graph convolutional networks for skeleton-based action recognition[C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2018, 32(1): 7444-7452.
- [25] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). June 27-30, 2016, Las Vegas, NV, USA. IEEE, 2016: 770-778.

- [26] Mathis A, Mamidanna P, Cury K M, et al. DeepLabCut: markerless pose estimation of user-defined body parts with deep learning[J]. *Nature Neuroscience*, 2018, 21(9): 1281–1289.
- [27] Fang H S, Li J F, Tang H Y, et al. AlphaPose: whole-body regional multi-person pose estimation and tracking in real-time[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(6): 7157–7173.
- [28] Wang C Y, Bochkovskiy A, Liao H M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). June 17–24, 2023, Vancouver, BC, Canada. IEEE, 2023: 7464–7475.
- [29] Sun K, Xiao B, Liu D, et al. Deep high-resolution representation learning for human pose estimation[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). June 15–20, 2019. Long Beach, CA, USA. IEEE, 2019: 5686–5696.
- [30] Jiang T, Lu P, Zhang L, et al. RTMPose: real-time multi-person pose estimation based on MMPose[EB/OL]. 2023; arXiv:2303.07399. <https://arxiv.org/abs/2303.07399v2>.
- [31] Li Y J, Yang S, Liu P D, et al. SimCC: a simple coordinate classification perspective for human pose estimation[M]//Computer Vision-ECCV 2022. Cham: Springer Nature Switzerland, 2022: 89–106.
- [32] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors[J]. *Nature*, 1986, 323(6088): 533–536.
- [33] Chen T Q, Guestrin C. XGBoost: a scalable tree boosting system[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco California USA. ACM, 2016: 785–794.

责任编辑: 周广礼