

基于可见光光谱和 YOLOv2 的生猪饮食行为识别

嵇杨培¹, 杨颖^{1*}, 刘刚^{1,2,3}

1. 中国农业大学信息与电气工程学院, 北京 100083
2. 现代精细农业系统集成研究教育部重点实验室, 北京 100083
3. 农业部农业信息获取技术重点实验室, 北京 100083

摘要 猪的进食、饮水行为是评价生猪健康程度最直接的依据, 利用计算机视觉技术实时监控生猪的进食、饮水等状况对提高生猪养殖福利有重要的意义。提出一种基于可见光光谱和改进 YOLOv2 神经网络的生猪进食、饮水行为识别方法, 该方法在生猪可见光图像序列上构建头颈模型, 结合改进的 YOLOv2 神经网络实现真实养殖场景中的生猪目标检测, 并利用位置信息对生猪的进食、饮水行为进行预判, 对符合判断的图像使用图像处理方法精准判断生猪进食、饮水行为。首先在生猪图像序列上构建头颈模型, 利用未被遮挡的头颈作为检测目标, 该模型能有效改善生猪目标检测过程的遮挡问题, 且能够精准定位生猪的头部, 为后续识别进食饮水行为提供辅助。然后采用国际主流神经网络 YOLOv2 作为目标检测的基础网络模型, 改进其激活函数, 实现快速精准地生猪目标检测。在使用网络训练前, 对生猪数据集使用 K-means 算法进行聚类候选边框, 其 mAP 值和 Recall 值相比于最初 YOLOv2 提高了 3.94% 和 5.3%。为了增加网络对输入变化或噪声的鲁棒性, 对比使用 ReLU, Leaky-ReLU 和 ELU 三个激活函数的性能, 可以发现使用 ELU 的性能比前两者有明显提高。将改进后的网络与原 YOLOv2, SSD 模型以及 Faster R-CNN 相比, 该模型的 mAP 值达到 90.24%, Recall 值达到 84.56%, 均优于后三者。最后利用目标检测得到的生猪头颈位置信息, 对生猪的进食、饮水行为进行预判。当图像中进食、饮水区域出现生猪时, 对该图进行背景差分法、形态学运算等处理, 并结合饮水区域停留时间等对生猪的进食、饮水行为进行更精准判断。实验表明: 利用该方法判断生猪的进食、饮水行为, 准确率分别达到 94.59% 和 96.49%, 均优于直接使用传统方法判断的结果, 可应用于实际养殖过程中辅助养殖人员进行生猪管理。

关键词 可见光光谱; 生猪; 目标检测; 深度学习; 行为识别

中图分类号: TP391.4 **文献标识码:** A **DOI:** 10.3964/j.issn.1000-0593(2020)05-1588-07

引言

作为人类生活必不可少的营养品和消费品, 猪肉产品的品质 and 环境污染、食品安全、人类健康息息相关。进食、饮水量不充足, 饲养管理缺乏科学依据, 生理疾病等都会导致猪只营养缺失, 影响商业价值。目前, 生猪养殖过程自动化水平较低, 过于依赖人工饲养, 不能提供连续、准确、实时的监控和观察。因此, 采用智能化的方法检测猪的进食、饮水行为, 分析其进食、饮水的规律, 对预警生猪疾病、维护猪的福利有很重要的作用。

目前已有的判断动物进食、饮水行为的方法, 主要分成

两大类: 基于无线射频技术(RFID)和机器视觉技术。Mase-lyne^[1]、Brownbrandl^[2]等通过 RFID 计量饮水量、投喂量, 从而达到低成本、高收益的效果。Roland^[3]等利用三轴加速度传感器监测小牛的饮水量, 以此研究饮水量与小牛健康的关系。此类传感器能实际记录各项参数, 但容易因为动物的咬食而损坏。机器视觉技术因为其无接触、成本低等优点在生猪养殖过程中得到大量应用。利用机器视觉技术对生猪的进食、饮水行为进行识别主要通过识别猪体姿态和生猪活动区域两种方式。Jinseong^[4]等使用空插值技术消除深度噪声, 实现夜间跟踪, 为夜间监测生猪异常提供依据。通过活动区域判断方面, 杨秋妹等^[5]利用传统方法提取猪只目标和行为预判, 再利用深度学习方法构造头部检测器, 精准判断生

收稿日期: 2019-04-11, 修订日期: 2019-08-27

基金项目: 国家“十三五”重点研发计划项目(2016YDD0700204)资助

作者简介: 嵇杨培, 女, 1995年生, 中国农业大学信息与电气工程学院硕士研究生 e-mail: hjypfighting@163.com

* 通讯联系人 e-mail: hbxyy@126.com

猪的饮水行为, 识别率达 92.11%。有研究^[6]通过使用 CCD 相机监测生猪, 利用图像识别饮水器、水表监测用水量, 建立饮水器与饮水量之间的动态模型, 准确率达 92%。

以上实验多是设置特定的实验环境以及针对特定的姿势实现行为识别, 为了解决真实养殖场景中快速、准确地识别生猪的进食、饮水行为的问题, 利用 YOLOv2 神经网络结合头颈模型解决生猪目标检测问题, 并利用头颈位置信息粗略判断生猪的行为。在检测基础上使用图像占领指数、背景差分等方法精准判断生猪进食、饮水行为。实验表明头颈模型检测方法能够有效解决部分遮挡问题, 准确获取生猪位置信息, 精确判断生猪发生的进食、饮水行为, 为进一步研究生猪其他行为提供支持。

1 实验部分

1.1 数据采集

实验数据采集于中国农业大学西校区的养殖园, 栏内共有两头重约 30 kg 的大长约克猪。2018 年 11 月 20 日至 2018 年 12 月 8 日, 在可见光条件下拍摄。将高清摄像头(海康威视, 型号: DS-2CDTFD-3W/R/32G-T, 分辨率为 1 080 pix×720 pix)固定于正对猪栏的墙上, 距离地面 2.8 m 处。猪栏的面积大小为 2 m×1.5 m, 底部高于地面 0.5 m, 摄像头所拍摄的面积比猪栏面积略小。

1.2 生猪进食、饮水行为识别方法设计

为实现快速、准确地识别真实场景中生猪进食、饮水行为, 设计了以下实验方法。通过在图像序列上构建头颈模型, 改善生猪目标检测过程中的遮挡问题。选用国际主流目标检测模型 YOLOv2, 实现真实场景中目标生猪的检测, 为进一步识别日常行为提供辅助。使用 K-means 算法进行聚类候选边框, 以缩短训练时间以及提高预测精度。通过替换激活函数, 以期加快网络收敛速度、增强网络对噪声的鲁棒性。在利用目标检测的位置信息实现粗略地日常行为识别的情况下, 使用背景差分法、图像占领指数等方法分割图像, 进一步实现生猪精准行为识别。

1.3 YOLOv2 网络简介

YOLOv2 是一个基于深度学习方法的端到端的物体检测深度网络, 实时和有效是 YOLOv2 最大的特点与优势, 能够在快速检测的同时, 保证物体的定位精度^[7]。YOLOv2 是 YOLO(You Only Look Once)的改进版, 在 YOLO 的基础上, YOLOv2 主要做了以下改进: 在卷积层后添加 batch normalization, 修改预训练分类网络的分辨率, 移除全连接层, 维度聚类, 能够在保持分类准确率的基础上, 提高对物体定位的准确度。

2 结果与讨论

生猪目标检测和进食、饮水行为识别的框架图如图 1 所示。内容包括头颈模型获取、目标生猪检测和进食、饮水行为识别三个部分。

所设计的生猪目标检测模型, 使用 Tensorflow 深度学习

平台, GPU 模式(NVIDIA Tesla K40m, 内存 12G)。

根据真实猪舍场景下的生猪目标检测问题的特点, 选择使用召回率 recall 和平均准确率均值 mAP 作为生猪目标检测模型的评价指标。

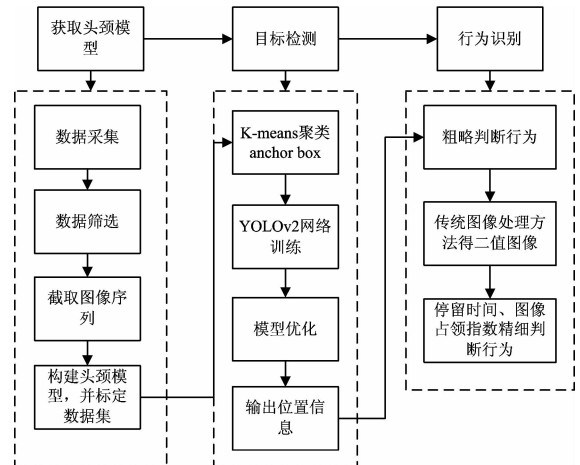


图 1 生猪行为识别框架图

Fig. 1 Framework of Pig behavior recognition

2.1 头颈模型获取

从采集到的生猪视频中筛选出有效视频数据, 人工记录 15 天中生猪发生的进食、饮水次数, 以便与本算法计算结果做比较。利用 PotPlayer 视频编辑器, 将视频截取成图像序列。原猪舍中有两个猪栏, 本文只针对其中一个猪栏内的生猪展开研究, 因此将原图由 1 920×1 080 大小截取成 1 396×1 080 大小的图像。

对于实际养殖场中的生猪目标检测问题, 最重要的是解决生猪之间的遮挡、重叠问题。当猪圈中出现遮挡、重叠时, 被遮挡部分的属性信息甚至关键属性信息丢失会影响检测生猪整体的特征。不能较好地解决遮挡、重叠问题, 实际养殖场中的检测准确率就得不到保证。通过分析大量密集型养殖场的监控数据, 可以发现生猪的头颈部位在数据中的可见性较高, 无论是身体部分如何遮挡、重叠, 生猪的头颈部位依旧具有较高的稳定性^[11]。在获取的数据中选择 2 300 张图片作为训练集, 600 张图片作为测试集。利用 LabelIMG 工具标定训练集中生猪头颈(包含嘴巴到整个耳朵)部位, 该数据集包含 4 600 个头颈部位。将所使用的头颈模型与原来使用的全身模型检测结果作对比, 实验结果如表 1 所示, 检测效果对比展示如图 2 所示。本模型在生猪出现遮挡、重叠等现象时, 效果优于全身模型。

表 1 头颈模型和全身模型实验结果

Table 1 Results of head-neck model and whole-body model

模型	mAP/%	recall/%
头颈模型	87.47	80.19
全身模型	84.23	76.75

2.2 目标生猪检测

以三组对比实验来证明生猪目标检测模型的可用性。



图 2 头颈模型与全身模型效果对比图

Fig. 2 Contrast diagram of head-neck model and body model

首先对比使用原始边框和聚类得到的边框效果；然后对比使用不同激活函数的性能；最后将本文优化得到的检测模型与主流目标检测模型进行对比。

2.2.1 候选边框聚类

为了缩短模型的训练时间以及提高最终的预测精度，初始边框选择的好坏显得尤为重要。不同数据集中目标大小及位置也不尽相同。在模型的学习过程中，根据事先选取的候选框预测，并不断对边框的位置和尺寸进行回归。因此采用 K-means 算法对生猪数据集中打好标签的生猪头颈边框进行聚类，得到适合本数据集的初始候选框的数量和参数。标准的 K-means 聚类计算距离的方法使用的是欧氏距离，而 YOLOv2 作者使用的距离的公式如式(1)所示

$$\text{Dis}(\text{box}, \text{centroid}) = 1 - \text{IOU}(\text{box}, \text{centroid}) \quad (1)$$

式(1)中: centroid 是聚类时被选作中心的边框, box 是除此之外的其他边框, Dis 则表示这两者之间的距离, IOU (Intersection-Over-Union) 表示预测边框与真实区域面积的交并比, 当 IOU 值越大时, 两者之间的距离越小, 由此得到的候选框大小越适合本数据集。

分别采用原 YOLOv2 的边框和用 K-means 聚类得到的边框进行训练, 同时保持模型的其他参数和激活函数不变, 最终实验结果如表 2 所示。

表 2 不同数量、大小候选框对比结果

Table 2 Results of clustering frames with different Numbers and sizes

初始候选边框	mAP/%	recall/%
原 YOLOv2	85.62	78.04
2 个聚类候选框	86.12	80.32
3 个聚类候选框	86.74	80.75
4 个聚类候选框	89.56	83.34
5 个聚类候选框	89.72	83.56

如表 2 所示, 随着聚类框个数的增加, 模型的性能呈现上升的趋势。但增加候选边框会增加模型的训练时间、消耗更夺硬件资源, 因此不考虑通过增加候选框的个数来达到较优的检测效果。使用四个、五个聚类框的性能没有太大的变化, 因此选取四个聚类候选边框。优选的聚类框在测试集中的直接表现是能将距离摄像头较远的生猪检测出来, 如图 3 所示。

2.2.2 YOLOv2 网络模型优化

YOLOv2 网络是使用一个单独的卷积模型实现端到端的目标检测。在生猪目标检测模型训练的过程中, 不仅需要生猪预测框的尺寸位置进行学习, 还需要对生猪的特征进行学习, 且学习过程中噪声较多, 要解决的问题复杂, 因此选取合适的激活函数对卷积神经网络的学习至关重要。

目前神经网络中使用较多的激活函数是 ReLU (rectified linear unit)^[8], 其公式定义如式(2)

$$y = \begin{cases} 0, & x \leq 0 \\ x, & x > 0 \end{cases} \quad (2)$$

相对于 sigmoid 函数和 tanh 函数, 其在输入正数时, 不存在梯度饱和问题, 且计算速度快了很多。但是当输入为负数时, 会出现神经元死亡的情况。

Leaky ReLU (leaky rectified linear unit) 是对 ReLU 的一个改进版, 和 ReLU 相比, 在负数区域内, PReLU 有一个很小的斜率, 可以避免神经元的死亡问题^[9], 其定义公式如式(3)

$$y = \begin{cases} 0.01x, & x \leq 0 \\ x, & x > 0 \end{cases} \quad (3)$$

Leaky ReLU 也是目前 YOLO 所采用的激活函数, 虽然保留了 x 取负值时候的输出, 但这部分输出不具备一定的抗干扰能力。

针对以上的分析, 在网络的每一个卷积层后使用 ELU 激活函数, 其定义公式如式(4)



图 3 使用优选聚类候选框的生猪检测结果

Fig. 3 The pig detection results of optimized clustering candidate box

$$y = \begin{cases} e^x - 1, & x \leq 0 \\ x, & x > 0 \end{cases} \quad (4)$$

与 ReLU 和 Leaky ReLU 相比, 当输入为正值时相同, 而输入为负数时则采用的是指数函数。从 ELU 的函数图像看, 坐标轴左侧部分软饱和能够增加 ELU 对输入变化或噪声的鲁棒性; 而坐标轴右侧部分采用线性函数, 能够缓解梯度消失问题^[10]。其输出的值均接近于零, 能够增加其收敛速度。

选取 ReLU, Leaky-ReLU 以及 ELU 三个激活函数验证不同激活函数对生猪目标检测模型的影响。同时不改变模型其他参数的条件, 只改变卷积层中的激活函数。最终得到的检测模型性能如表 3 所示。

表 3 不同激活函数的性能比较

Table 3 Performance comparison of different activation functions

激活函数	mAP/%	recall/%
ReLu	87.47	80.19
Leaky-ReLU	89.56	83.34
ELU	90.24	84.56

如表 3 所示, 不同的激活函数对生猪目标检测的性能影响有所不同。当模型使用 ELU 激活函数时, 测试集上的 mAP 对比前两者分别高出了 0.68% 和 2.77%, 召回率分别高出了 1.22% 和 4.37%。

如图 4 所示, 当猪舍中生猪出现不同程度的遮挡、猪舍中光照变化等引起的图像中噪声信息, ELU 激活函数比其他两者对噪声信息具有较强的鲁棒性。因此无论是检测能力还是收敛速度, 都强于前两者。

最后将生猪目标检测模型与其他不同的模型进行对比, 最终在测试集上性能如表 4 所示。实验表明, 使用本文改进后的 YOLOv2 算法对生猪进行目标检测, 无论是在检测效率

还是检测精度上均优于其他 3 种算法, 可作为生猪目标检测的模型使用。

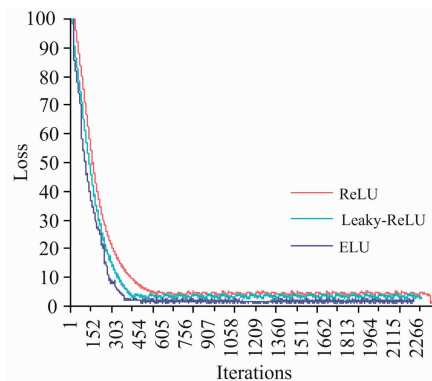


图 4 不同激活函数 Loss 曲线图

Fig. 4 Loss curve of different activation functions

表 4 不同模型性能比较

Table 4 Performance comparison of different models

模型	mAP/%	recall/%
Faster R-CNN	82.21	83.19
SSD	83.87	81.25
YOLOv2	85.62	78.04
本研究	90.24	84.56

2.3 进食、饮水行为识别

进食、饮水部分的技术路线图如图 5 所示, 通过上述目标检测阶段得到的检测框左下角坐标, 判断生猪是否处于进食或饮水区域, 从而达到一个粗略的行为识别结果。当生猪处于进食、饮水区域时, 读取该图像并分割, 得到前景目标。利用进食、饮水区域的图像占领指数以及生猪在该区域停留的时间精细判断生猪是否真正发生了进食、饮水行为, 并进行记录。

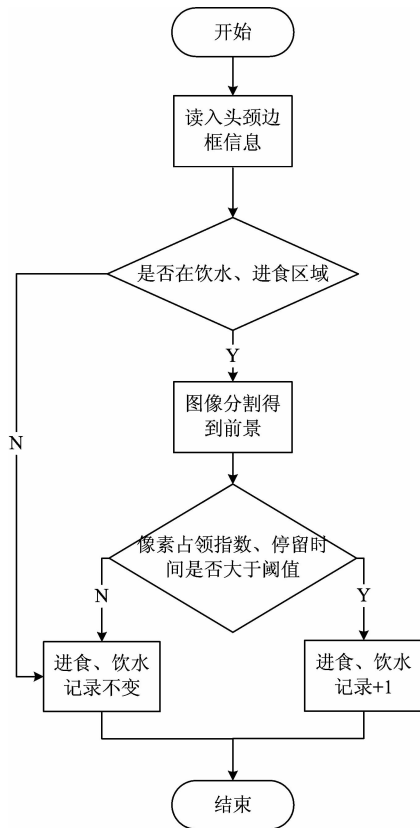


图 5 进食、饮水技术路线图

Fig. 5 The flow chart of eating and drinking behavior recognition

背景差分法可用于对静止场景中的目标进行分割, 该方法的原理是将当前的图像与背景图像做差分运算, 对得到的前景目标区域再进行阈值化, 获取目标。如图 6(b)所示为生




图 6 分割效果图

Fig. 6 Segmentation results

猪背景图, 图 6(a)所示为图像序列中的某一帧, 通过背景差分法得到前景区域如图 6(c)所示。对背景差分得到的图像进行膨胀、腐蚀等形态学操作并删除小联通区域, 得到的分割图像如图 6(d)所示。

如图 6 所示, 处理得到的二值图像中, 以饮水行为为例, 将饮水区域记为 S , $\text{Area}(S)$ 表示饮水区像素点的值总和, 饮水区占领指数记为 R_{Occupied} 。 S 区域的像素点坐标记为 (x, y) , 猪只头部区域像素点的值记为 $F(x, y)$ 。当猪只的头部进入饮水区域后, 将覆盖在该区域的像素点的值记为 1, 其余记作 0。饮水区 S 的占领指数公式定义如式(5)

$$R_{\text{Occupied}} = \frac{\sum_{(x, y) \in S} F(x, y)}{\text{Area}(S)},$$

$$\begin{cases} F(x, y) = 1, & (x, y) \in S \\ F(x, y) = 0, & (x, y) \notin S \end{cases} \quad (5)$$

生猪进食、饮水区域像素占领指数以及停留时间均有一定的规律。当 R_{Occupied} 超过设置的阈值时, 且在该区域停留的时间大于 2 s、小于 4 min 时, 判定该生猪发生了进食或饮水行为, 计数加 1。像素比值的阈值根据多组实验求得, 停留时间小于 2 s 时可能是猪只经过进食、饮水区域, 大于 4 min 可能是在进食、饮水区躺卧休息。

在抽取的 15 个视频中, 将本算法检测到的生猪进食、饮水次数与人工记录结果进行对比, 结果如表 5 和表 6 所示。据统计, 人工观察视频记录的饮水、进食次数分别为 80 次和 127 次, 通过本文算法共检测出 74 次饮水和 114 次进食。与实际结果相比, 正确饮水、进食的次数分别为 70 次和 110 次, 将非饮水、进食行为错误识别次数分别为 4 次和 4 次, 实际发生饮水、进食行为却未检测出的次数分别为 10 次和 17 次。出现误判的主要原因是生猪在进食、饮水区活动, 符合判断的条件, 但没有发生进食或饮水行为; 出现漏判的主要原因是网络自身对比较小的物体检测效果差。

表 5 饮水行为实验结果

Table 5 Results of drinking behavior

视频编号	饮水次数/次		视频编号	饮水次数/次	
	本文算法	人工记录		本文算法	人工记录
1	6	6	9	8	7
2	5	6	10	5	4
3	5	5	11	11	10
4	5	4	12	0	1
5	4	6	13	2	2
6	4	5	14	3	3
7	2	2	15	6	7
8	8	12			

表 6 进食行为实验结果

Table 6 Results of eating behavior

视频编号	进食次数/次		视频编号	进食次数/次	
	本文算法	人工记录		本文算法	人工记录
1	9	9	9	9	9
2	5	8	10	1	2
3	5	5	11	8	10
4	3	3	12	7	5
5	16	21	13	8	10
6	7	6	14	5	5
7	3	3	15	9	8
8	19	23			

利用本方法正确识别出的进食、饮水次数与所检测出的次数之比定义为进食、饮水的准确率,将正确识别行为的次数与实际视频中发生的行为次数之比定义为召回率,由此计算得到的猪只饮水、进食准确率分别为 94.59% 和 96.49%,召回率为 87.5% 和 86.61%。另外不使用头颈模型及神经网络,仅使用背景差分、图像占领指数等传统图像处理方法识别生猪进食、饮水行为,其识别结果如表 7 所示。从对比结果可以看出,采用本方法的行为识别准确率和召回率均高于传统方法。传统方法无法直接判断在饮水区域的是头部还是尾部,视频采集过程中光线的变化会导致生猪目标获取不完整,且需要对每一张生猪图像进行处理判断,耗时耗力。而本文使用神经网络结合头颈模型可直接检测到生猪头部,对符合预判段的图像再进行后续的处理,不仅用时少,还能节省能源消耗。因此,本方法可用于识别生猪的进食、饮水行为。

表 7 行为识别结果对比

Table 7 Comparison of behavior recognition results

	进食准确 率/%	进食召回 率/%	饮水准确 率/%	饮水召回 率/%
本文方法	96.49	86.61	94.59	87.50
传统方法	87.29	81.1	87.18	85

3 结 论

提出了基于可见光光谱图像和 YOLOv2 网络的生猪进食、饮水行为智能识别算法。采用改进的 YOLOv2 网络结合所提出的头颈模型实现了猪只检测,算法准确率达 90.24%。相对于全身模型,所提出的头颈模型不仅能有效解决生猪的遮挡问题,而且能精准定位生猪的头部,为进一步判断进食、饮水行为奠定基础。在前期深度学习检测的基础上,通过计算图像占领指数、停留时间等识别生猪是否真正发生进食、饮水行为,准确率分别达到 94.59% 和 96.49%,无论是识别效率还是准确率均高于仅使用传统图像处理方法。本方法具有高度的通用性,针对生猪的进食、饮食行为识别提出的头颈模型,还可用于检测生猪的其他部位,为识别生猪的排泄等其他日常行为作辅助。当生猪发生排泄行为时,记录该行为发生的时刻,统计出一定时间内排泄行为发生的次数,再根据次数的多少来判断生猪是否存在异常,及时通知管理员并采取相应措施。本研究还未达成产业化的目的,仅是一个有益的探究,研究过程只依赖于猪舍的监控设备,投入成本低且对生猪无伤害,本研究结果可以为猪舍管理人员科学养殖、增加商业价值的提供参考。

References

- [1] Maselyne J, Adriaens I, Huybrechts T, et al. *Animal*, 2016, 10(09): 1557.
- [2] Brownbrandl T M, Rohrer G A, Eigenberg R A. *Computers & Electronics in Agriculture*, 2013, 96(6): 246.
- [3] Roland L, Lidauer L, Sattlecker G, et al. *Computers & Electronics in Agriculture*, 2018, 145: 298.
- [4] Jinseong K, Yeonwoo C, Yunchang C, et al. *Sensors*, 2017, 17(12): 2757.
- [5] YANG Qiu-mei, XIAO De-qin, ZHANG Gen-xing(杨秋妹,肖德琴,张根兴). *Transactions of the Chinese Society for Agricultural Machinery(农业机械学报)*, 2018, 49(6): 232.
- [6] Mohammadamin K, Claudia B, Sara A H, et al. *Computers & Electronics in Agriculture*, 2013, 90: 164.
- [7] Redmon J, Farhadi A. *IEEE Conference on Computer Vision and Pattern Recognition*. 2017. 6517.
- [8] Zhang X. *Computer Assisted Surgery*, 2017, 22(Sup1): 1.
- [9] Cai B, Xu X, Jia K, et al. *IEEE Transactions on Image Processing*, 2016, 25(11): 5187.
- [10] Ma K, Liu W, Zhang K, et al. *IEEE Transactions on Image Processing*, 2018, 99: 1.
- [11] Xu J, Denman S, Sridharan S, et al. *IEEE Transactions on Circuits and Systems for Video Technology*, 2015, 25(6): 1063.

Recognition of Pig Eating and Drinking Behavior Based on Visible Spectrum and YOLOv2

Ji Yang-pei¹, YANG Ying^{1*}, LIU Gang^{1,2,3}

1. College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China

2. Key Laboratory of Modern Precision Agriculture System Integration Research, Ministry of Education, Beijing 100083, China

3. Key Laboratory of Agricultural Information Acquisition Technology, Ministry of Agriculture, Beijing 100083, China

Abstract The eating and drinking behavior of pigs is the most direct evidence to evaluate the health degree of pigs. Therefore, it is of great significance to use real-time monitoring of the eating and drinking status of pigs by computer vision technology for improving the welfare of pig breeding. This paper proposes a recognition method of pig eating and drinking behavior based on visible spectrum and improved YOLOv2 neural network. The method builds head-neck model on the pig visible spectrum image sequence, making use of improved YOLOv2 neural network to realize target detection in the scene of the real pigsty, then utilizing the output of the position information for preliminary judgment of eating and drinking behavior. Then using traditional image processing methods to make an accurate judgment of pig eating and drinking behavior. First, the head-neck model is constructed in the sequence of pig images, and the unblocked head and neck were used as the detection target. This model can effectively solve the occlusion problem in the pig target detection processing, and can also accurately locate the head of the pig, providing assistance for the subsequent identification of eating and drinking behaviors. Then this paper adopted the international mainstream neural network YOLOv2 as the basic network model for target detection, and improve the activation function to achieve fast and accurate target detection of live pigs. Before network training, the K-means algorithm is used to cluster the target frame of the homemade pig data set. Compared with the initial performance of YOLOv2, the mAP value and the Recall value was improved by 3.94% and 5.3%. In order to increase the robustness of the network-facing input changes or noise, this paper compared the performance of the three activation functions of ReLU, Leaky-ReLU and ELU, and found that the performance of the ELU was significantly different from the former two. Compared with the original YOLOv2 and Faster R-CNN, the target detection model in this paper has a mAP value of 90.24% and a recall value of 84.56%, both of which are better than the latter two. Finally, the pig head-neck position information gets from target detection was used to make the preliminary judgment of eating and drinking behavior. When pigs appeared in the eating and drinking area of the picture, background difference method, morphological calculation and other image processing methods are performed on the picture, and the pig eating and drinking behavior is judged more accurately by combining with the residence time of the drinking area. The experiment shows that, the method used in this paper can be used to judge the eating and drinking behavior with an accuracy of 94.59% and 96.49%, which are better than the results judged by the traditional method directly, and can be applied to assist the management of breeding personnel in the actual breeding process.

Keywords Visible spectrum; Pigs; Target detection; Deep learning; Behavior recognition

(Received Apr. 11, 2019; accepted Aug. 27, 2019)

* Corresponding author