

doi:10.6041/j.issn.1000-1298.2019.S0.041

基于 Mask R - CNN 的猪只爬跨行为识别

李丹 张凯锋 李行健 陈一飞 李振波 蒲东

(中国农业大学信息与电气工程学院, 北京 100083)

摘要: 针对目前猪只爬跨行为自动化检测程度较低的问题,提出了一种基于 Mask R - CNN 的猪只爬跨行为识别算法。首先获取猪只俯视图像,利用 Labelme 制作数据集标签,引入迁移学习方法训练 ResNet - FPN 网络,获取猪只分割结果,并提取每个样本中的 mask 像素面积。提取每个样本中的最小 mask 像素面积作为爬跨行为识别的经验样本集,确定爬跨行为界定阈值。利用测试集分别测试猪只分割网络模型及爬跨行为识别算法,结果表明,猪只分割网络模型的分割准确率为 94%,爬跨行为识别算法准确率为 94.5%。本算法能够自动有效地检测猪只爬跨行为,可为牲畜养殖自动化提供支持。

关键词: 猪只; 爬跨行为; 迁移学习; Mask R - CNN; 界定阈值

中图分类号: TP391.41 **文献标识码:** A **文章编号:** 1000-1298(2019)S0-0261-06

Mounting Behavior Recognition for Pigs Based on Mask R - CNN

LI Dan ZHANG Kaifeng LI Xingjian CHEN Yifei LI Zhenbo PU Dong

(College of Information and Electronics Engineering, China Agricultural University, Beijing 100083, China)

Abstract: The mounting behavior of pigs is generally manifested as a pig puts two front legs on the body or head of another pig which stays lying or dodged quickly. Mounting between pigs often causes epidermal wounds and even fractures, which reduces animal welfare and affects the economic benefits. Therefore, it is necessary to isolate the mounting pigs in time. In view of the low degree of automation of current mounting behavior detection of pigs, an algorithm based on Mask R - CNN was proposed to recognize the mounting behavior of pigs. Firstly, the top view videos of pigs were shot, and the dataset labels were made by Labelme. The transfer learning was applied to train the ResNet - FPN network to obtain the pig segmentation result and extract the mask pixel area in each sample. The value of the minimum mask pixel area in each sample was extracted in order to build an empirical sample set for mounting behavior recognition, and the discriminant threshold of the mounting behavior of pigs was determined. In the experiment, the test dataset was used to evaluate the pig segmentation network model and the mounting behavior recognition algorithm. The segmentation accuracy of the network was 94%, and the accuracy of the mounting behavior recognition algorithm was 94.5%. The experimental results showed that the algorithm can effectively detect the mounting behavior of pigs and provide support for livestock breeding automation.

Key words: pigs; mounting behavior; transfer learning; Mask R - CNN; threshold classification

0 引言

我国猪肉进出口量近年不断攀升,养猪规模日渐扩大。猪肉品质与安全常与养殖过程中猪只健康和福利息息相关。多数牲畜疾病的临床或亚临床体征表现之前常伴随行为异常,为保证肉质健康及猪

只福利,对猪只行为监控显得尤为重要。目前人工监控是商业化猪场的主要监管方式,但人工监管存在劳动力成本高和主观误差等问题。因此,用于检测猪只行为的电子传感器应运而生,包括电子耳标^[1]、运动加速度计量器^[2]和压力垫^[3]等,但电子传感器的成本高,且易引起猪只的应激反应,故急需

收稿日期: 2019-04-20 修回日期: 2019-05-24

基金项目: 国家重大科技基础设施项目(4444-10099609)

作者简介: 李丹(1991—),女,博士生,主要从事计算机视觉与人工智能研究,E-mail: oliviald@126.com

通信作者: 陈一飞(1963—),男,教授,博士生导师,主要从事智能控制与人工智能研究,E-mail: glhfei@126.com

一种低成本、非接触式的行为监控方法。

利用视频图像处理技术可以有效解决上述问题,近几年已有大量基于视觉的猪只行为识别研究成果。现有基于视觉的猪只行为识别算法可分为4类:①日常行为视觉监测,如OTT等^[4]利用相对移动像素数量表征活动指数检测运动行为,陈紫城^[5]基于时空兴趣点与词袋模型对视频描述后,利用支持向量机分类识别采食等行为,杨秋妹等^[6]利用GoogLeNet网络训练头尾识别模型后,在饮水区域识别头部从而完成饮水行为检测,李振晔^[7]在排泄区通过检测猪只个体识别排泄行为,纪滨等^[8]构造脊腹线截距描述子和波动描述子检测呼吸行为等。②特殊时期行为视觉监测,如薛月菊等^[9]利用改进的Faster R-CNN识别母猪哺乳姿态。③危险行为视觉检测,如VIAZZI等^[10]利用运动历史图算法识别攻击行为等。④疾病视觉监测,如吴燕^[11]依据关键部位构建星形骨架,并根据形状变化实现跛脚检测。

爬跨行为类属危险行为,主要特征表现为爬跨猪只的前蹄攀上被爬猪只的背部,在猪只群生长的各个时期均常有发生,尤其发情期。在交互行为中经常造成皮肤创伤甚至骨折,影响猪只健康,降低福利,甚至影响猪肉品质,造成经济损失。NASIRAHMADI等^[12]对含有猪只的灰度图阈值分割,然后将猪只拟合为椭圆,根据椭圆轴长设定阈值判别猪只的爬跨行为。考虑到阈值分割受光照影响严重,且猪只间粘连易被拟合在同一圆内造成误判。因此,本文提出一种基于深度学习的猪只爬跨行为检测方法,先利用Mask R-CNN网络分割图中猪只得到mask,再求取每只猪只mask像素面积,求取界定阈值后,依据阈值识别爬跨行为。

1 数据采集与数据集制作

1.1 数据采集

实验数据采集于河北省涿州市中国实验小型猪培育基地,选取4只发情期哥廷根四系公猪放入尺寸约为2 m×2.2 m的栏位。自2018年6月11日起,上、下午分别拍摄3 h视频,为期7 d。将Allied Vision Technologies的Manta G-282C相机垂直向下悬挂于距地面约2.8 m的猪舍顶棚,以2 f/s速度获取俯视彩色图像。相机拍摄设置分辨率1 936像素×1 458像素,按拍摄日期存入移动硬盘。

1.2 数据集制作

从获取的图像中筛选2 800幅作为数据集,其中包括正负样本各1 400幅。正样本是指至少含有2只猪只具有爬跨行为特征的样本集合,负样本则

包含易混淆的猪只间粘连图像和4只猪体分离图像样本集合。所选样本集包含不同时间段、不同光照强度、不同环境清洁程度和不同猪体清洁程度的样本。样本选取后统一调整至640像素×480像素,在Labelme图像标注工具中利用多边形标注出猪只的外轮廓。标注文本文件经转换后得mask、label等文件。

2 算法原理

2.1 猪只爬跨行为识别体系架构

本方法通过俯视视角的可见光视频图像,自动分割栏位中的猪只并判断爬跨行为是否发生,具体体系结构如图1所示。

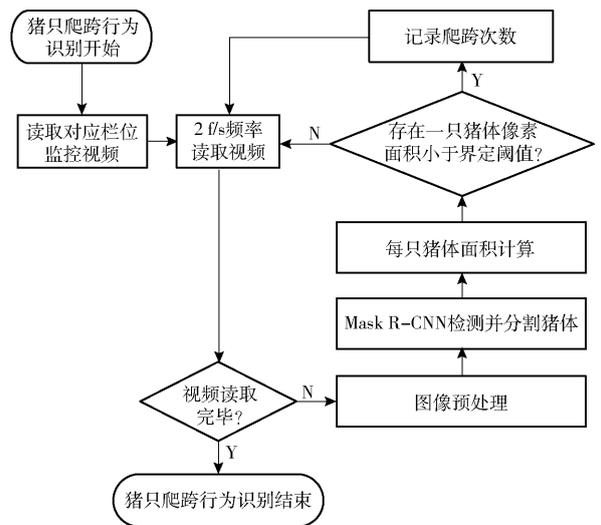


图1 猪只爬跨行为识别体系结构

Fig. 1 Framework for mounting behavior recognition

本文提出的基于深度学习的猪只爬跨行为识别算法主要由两部分组成,第1部分利用Mask R-CNN网络检测图像中的猪只并分割每只猪只的区域,得到分割后每只猪只的mask像素面积;第2部分则依据正负样本中具有爬跨行为和非爬跨行为猪只的mask像素面积,获取发生爬跨行为猪只的像素面积界定阈值。在检测爬跨行为过程中,若面积小于界定阈值,则判断该帧图像中有爬跨行为发生,否则没有,从而实现猪只爬跨行为自动识别。

2.2 基于Mask R-CNN的猪只分割

猪只分割是猪只检测的重点和难点,传统的阈值分割很难满足实际光照变化的需要。本文使用Mask R-CNN网络对猪只检测和分割。Mask R-CNN^[13]是在Faster R-CNN^[14]基础上改进得到的一种用于实例分割的深度学习网络,经文献[13]实验证明,其在重叠目标的分割效果优于同类的FCIS^[15]。因此,本文优先选用Mask R-CNN作为识别爬跨行为的猪只分割网络。

2.2.1 基于 Mask R-CNN 的猪只分割网络模型

如图 2 所示,基于 Mask R-CNN 的猪只分割网络结构可分为 3 部分:①主干网络,主干网络是共享的卷积层,用于对输入图像的特征提取,生成特征映射图(Featuremaps)。猪只分割网络选用残差网络(ResNet101)^[16]结合特征金字塔网络(FPN)^[17]作为主干网络,生成 P2、P3、P4、P5 等 4 级特征图。②区域建议网络(RPN),用于生成感兴趣区域(RoI)推

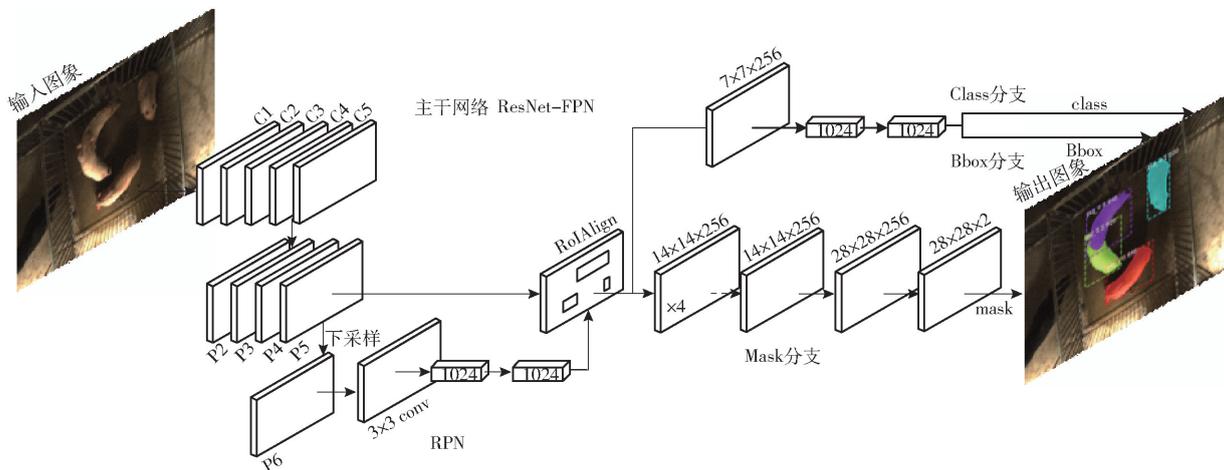


图 2 基于 Mask R-CNN 的猪只分割网络结构

Fig. 2 Structure of pig segmentation network based on Mask R-CNN

特别地,Mask R-CNN 网络结构中将 Faster R-CNN 的特征池化层 RoIPool 改为 RoIAlign。由于 RoIPool 池化匹配中由浮点数表示的感兴趣区域 RoI 量化到特征图的过程中存在一次取整操作,而在 RoI 池化分块的过程中又有一次取整操作,两次四舍五入取整易导致像素级的特征提取错位,使 mask 误差增大。RoIAlign 取消了取整操作并引入双线性插值法,更精确地找到每个块对应的特征,使得每个 RoI 取得特征能更好地对齐原图上的 RoI 区域。

2.2.2 基于迁移学习和 Mask R-CNN 的猪只分割流程

为了解决小样本数据集训练效果较差、收敛时间较长的问题,本文引入迁移学习的思想,利用 MS COCO 数据集^[18]上预训练好的参数模型初始化 Mask R-CNN 网络。结合标注好的猪只数据集对整个网络层进行 fine-tuning,获取猪只分割模型。

基于 Mask R-CNN 的猪只分割模型流程如下:

(1) 输入图像进入残差网络进行特征提取。

(2) ResNet 第 1~4 阶段生成 P2~P5 共 4 个尺度特征图,用于 RPN、Bbox 及 mask 生成。

(3) 由 P5 以步长为 2 进行下采样得特征图 P6, P6 仅用于 RPN。

(4) RPN:提取 P2~P6,对不同尺度特征图进行

荐框。本网络中 RPN 涉及的特征图来自 FPN 中金字塔特征层,首先由 P5 下采样得到 P6,再分别在 P2~P6 中提取 5 种不同尺度的长宽比为 0.5、1 和 2 的 15 种矩形框作为 RoIs。③三分支,用于回归检测物体的类别、矩形框(Bounding-box, Bbox)及 mask。本文中类别包含 2 类(猪只和背景),Bbox 包含 4 个参数均由全连接层得出。Mask 层包含 5 个卷积层和 2 个反卷积层,其中最后一层输出 mask 类别设置为 2 类。

卷积,在每个位置生成 3 个 anchor。针对 class 生成 3×2 个(猪只和背景 2 类)卷积核,对 Bbox 生成 3×4 个卷积核。在 3×3 卷积层后接两个 $1 \times 1 \times 1$ 024 的全连接层,完成每个像素的前后景判别及猪只的第 1 次 Bbox 修正。

(5) RPN 生成推荐 RoI 的 Bbox 送入特征池化层 RoIAlign,在 RoIAlign 中,根据 Bbox 提取 P2~P5 特征送入三分支网络。

(6) 分类与边框回归分支根据 RoI 完成前后景类别打分及猪只 Bbox 第 2 次修正,Mask 分支经过卷积和反卷积层生成猪只 mask,完成猪只检测与分割。

2.3 基于界定阈值的爬跨行为识别

猪只分割后生成每只猪的 mask 图,一幅图生成 4 个 mask,分层提取每个 mask 的像素个数得到每只猪像素面积,定义为 S_1 、 S_2 、 S_3 和 S_4 。 $S_1 \sim S_4$ 不区分个体,仅代表一幅图上 4 只猪的 4 个像素面积。

定义数据集由 N 幅图像的向量集合 \mathbf{F} 表示,则 $\mathbf{F} = \{F_1, F_2, \dots, F_i, \dots, F_N\}$,其中, $F_i = \{S_{i1}, S_{i2}, S_{i3}, S_{i4}\}$, $i = 1, 2, \dots, N$ 。求取每个 F_i 中的猪只 mask 像素面积最小值 S_{imin} ,构成集合 $S_{MIN} = \{S_{1min}, S_{2min}, \dots, S_{Nmin}\}$ 。

分析数据集中所有样本图像 \mathbf{F} 的每个 mask 面积 S ,不难发现,具有攀爬行为的猪只 mask 面积 $S_{mounting}$ 均小于分离猪只的面积 $S_{separation}$ 。因此,定义

爬跨行为的界定阈值 Threshold(T),则有

$$F_i = \begin{cases} F_{\text{Positive}} & (S_{\text{imin}} \leq T) \\ F_{\text{Negative}} & (S_{\text{imin}} > T) \end{cases} \quad (1)$$

式中 F_{Positive} ——发生爬跨行为的样本

F_{Negative} ——未发生爬跨行为的样本

假设 F 中有 M 个正样本和 G 个负样本,在界定阈值 T 为 T_x 时, F_{Positive} 个数为 m , F_{Negative} 个数为 g ,则错误分类个数为 $|m - M| + |g - G|$ 。此时定义爬跨行为判别准确率为 P_{mounting} ,则猪只爬跨行为的界定阈值应满足最优化公式

$$\min: -P_{\text{mounting}} = -\frac{N - (|m - M| + |g - G|)}{N} \times 100\% \quad (2)$$

为了使得式(2)最小,即爬跨行为判别准确率最高的界定阈值 T ,本文采用经验阈值遍历法,在大量数据集 S_{MIN} 中遍历 T ,找到一个合适的经验阈值。

3 实验与结果分析

本算法实验分为基于 Mask R-CNN 的猪只分割实验和猪只爬跨行为识别实验。

3.1 猪只图像分割实验

3.1.1 实验环境

猪只分割网络模型实验采用至强 E5-2667CPU,主频 3.2 GHz,128 GB 内存,GPU 为 NVIDIA GeForce GTX1080 的硬件平台,搭载 CentOS7 系统,Python 编程语言实现。

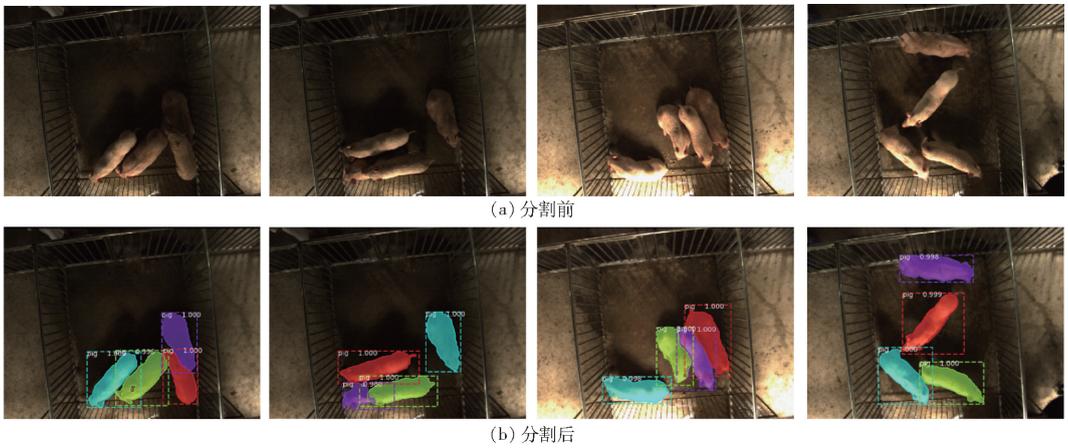


图3 基于 Mask R-CNN 的猪只分割结果

Fig.3 Segmentation results of pigs based on Mask R-CNN

分析实验所选的随机测试集,其中包含正负样本各 100 个。每个正样本包含至少 2 只猪正在发生爬跨行为,负样本包含多只猪粘连及分离的情况,具体分割情况如表 1 所示。

测试样本中,正样本分割正确 92 幅,负样本分割正确 96 幅,总分割准确率为 94%。200 幅样本包含猪只 800 只,正确分割 787 只,准确率 98.37%。

3.1.2 模型训练

训练过程采用迁移学习方法,利用经 MS COCO 预训练的参数初始化网络,后微调至效果理想。具体步骤如下:

- (1)制作具有标签、mask 的数据集,并随机划分 2 800 幅图像,抽取 2 200 组训练样本数据集(包含爬跨行为图像 1 150 幅)、200 组验证集和 200 组测试集,剩余 200 组作算法整体测试集,使其互相之间无交集。
- (2)加载预训练好的 MS COCO 模型参数。
- (3)修改配置参数及分类参数。
- (4)开始训练,观察网络损失曲线及验证集准确率变化。
- (5)调整 RPN 的 anchor 尺度、学习率等参数。
- (6)使用测试集数据检测猪只分割模型,获取分割图像。
- (7)评估测试集准确率。
- (8)重复步骤(5)~(7),至测试集达理想准确率。

完成调参后,设定 RPN 的 5 个 anchor 尺度为 24、48、96、192、384,positive IoU 设定为 0.7,学习率为 10^{-3} ,权重衰减 10^{-4} ,冲量设定为 0.9。

3.1.3 猪只分割结果及分析

将随机选取的 200 个测试集输入猪只分割网络,利用训练好的猪只分割网络对测试集进行准确率检测,部分猪只分割结果如图 3 所示。

表 1 测试样本猪只分割结果

Tab.1 Analysis of pig segmentation results 只

样本类型	分割正确	未识别	分割错误
涉及爬跨的猪只	208	3	3
粘连猪只	105	2	1
彼此分离猪只	474	3	1
总计	787	8	5

涉及爬跨行为的猪只 214 只, 准确分出 208 只, 准确率为 97.20%, 彼此粘连猪只 108 只, 准确分出 105 只, 准确率为 97.22%, 彼此分离猪只 478 只, 准确分割 99.16%。由数据显示, 在不同光照强度、不同地面清洁程度及猪只不同清洁程度情况下, 网络对于猪只分割效果均比较理想。

测试样本中未能准确识别的多为发生爬跨行为程度较高, 重叠面积过大, 网络将交叠猪只识别为同一只的情况, 如 3 只猪彼此交叠。分割错误的多为 mask 形状畸形, 猪只交叠处分割边界有误。发生漏检和错检的原因, 主要由于图像是由视频帧中抽取到的, 猪只爬跨过程中重叠部分由小到大, 分割错误的图像多发生于爬跨事件的后期。

3.2 猪只爬跨行为识别实验

3.2.1 爬跨行为界定阈值选取

从数据集中选取 1 436 组数据, 提取标注过程中的 mask 像素面积构成经验样本集。提取经验样本集中每幅图像标注的最小 mask 像素面积值, 构成爬跨行为判别的 mask 像素面积经验集合, 如图 4 所示。

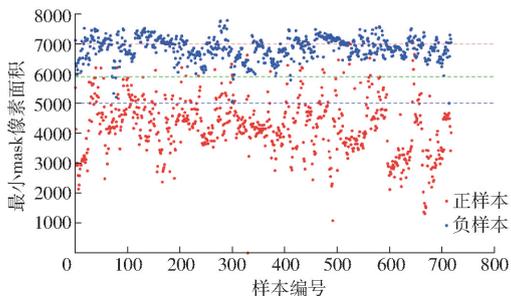


图4 经验集猪只最小 mask 像素面积

Fig. 4 Minimum pixel area of pig's mask of experience dataset

图 4 中横坐标表示样本编号, 纵坐标表示像素面积, 样本不分先后顺序。红色虚线表示正样本中, 最小 mask 像素面积最大值为 6 987。蓝色虚线表示负样本中, 最小 mask 像素面积最小值为 5 012。不难看出, 能够将两类样本尽可能分类的爬跨行为界定阈值 T 应在红蓝线之间, 即 $T \in (5\ 012, 6\ 987)$ 。

以 1 为步长, 在 5 012 ~ 6 987 范围内遍历 T , 得到当 $T \in (5\ 892, 5\ 912)$ 时, 依据界定阈值分类错误

个数最少, 为 35 个, 分类准确率 $P_{\text{experience}} = \frac{1\ 436 - 35}{1\ 436} \times 100\% = 97.56\%$ 。即当阈值取 5 892 ~ 5 912 之间时, 经验集分类准确率最高, 为 97.56%。本文选用 5 896 为爬跨行为界定阈值。

3.2.2 爬跨行为识别结果及分析

进行爬跨行为识别实验时, 将数据集中预留的行为检测测试集输入 Mask R-CNN 猪只分割网络, 提取每只猪的 mask 像素面积。提取每个样本的最小 mask 像素面积值, 构成爬跨行为测试样本集, 如图 5 所示。

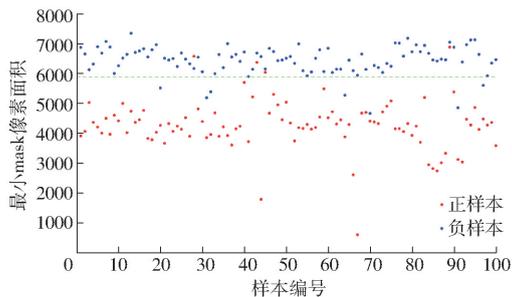


图5 测试集猪只最小 mask 像素面积

Fig. 5 Minimum pixel area of pig's mask of test dataset

图 5 中横坐标表示测试样本编号, 纵坐标表示像素面积。绿色虚线为界定阈值分割线 (5 896)。此时正样本错分 4 个, 负样本错分 7 个。依据当前界定阈值的分类准确率为

$$P_{\text{mounting}} = \frac{200 - (4 + 7)}{200} \times 100\% = 94.5\%$$

实验表明本方法具有较高的准确率, 能够较好地分类爬跨行为。实验过程中, 发现本算法在一些轻度粘连的图像中表现优于文献 [12] 中提出的爬跨行为识别算法, 如图 6 所示。

图 6a ~ 6d 为传统方法实现过程, 为了平衡光照影响, 将图像转至 HSV 色彩空间后对 V 通道直方图均衡化得到图 6b, 采用最大类间方差法 (大津法 [19]) 确定分割阈值, 经阈值分割后得图 6c, 经形态学闭运算及 Canny 算子 [20] 边缘检测后, 对二值图椭圆拟合 [21] 并保留关键区域得到图 6d。由图可见, 一只位于光照较强区域的猪只未被检测出, 粘连的 3 只猪只被拟合为 2 个椭圆且椭圆短轴约为正常猪只的 1.5 倍, 依据文献 [12] 将被判别为

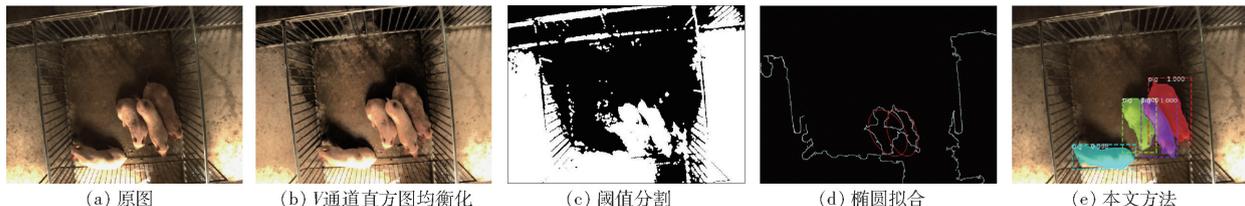


图6 爬跨行为识别效果对比

Fig. 6 Comparison of mounting behavior recognition effects

发生爬跨行为,识别错误。图6e为经本文提出的猪只分割模型处理后的图像,分割正确且图中最小mask像素面积为7035,大于爬跨界定阈值5896,分类器判定为未发生爬跨行为,识别正确。可见,本算法在背景光照变化多样、猪体与背景颜色接近及猪体轻度粘连等情况下分类效果优于传统方法。

实验中,算法未能准确识别爬跨行为的情况主要包含两种:①正样本识别为负样本,可能由猪只分割模型未能识别被爬猪只造成,即mask像素面积较小的被爬猪只未被分割出,导致正样本中最小mask像素面积超过界定阈值而被判为未发生爬跨行为。②负样本识别为正样本,可能由部分粘连猪只互相重叠面积过大造成,部分样本中猪只的头部甚至半个身体倾至俯卧猪只身体上方,俯视视角下两只猪只重叠面积较大。此类样本在划分样本集时被划分到负样本中,但单只猪只面积小于界定阈值,因此错判为爬跨行为。

4 结论

(1)针对难以用传统图像处理方法解决的猪只爬跨行为识别问题,提出了一种基于Mask R-CNN的爬跨行为识别方法。根据专家经验,将视频拍摄的猪只图像分为具有爬跨行为的正样本图像和包含猪只间粘连及分离的负样本图像。统一使用Labelme标注为标准样本集。

(2)基于迁移学习和Mask R-CNN网络,训练猪只分割模型。经过反复调参,模型在200组测试集上获得单幅图像94%的正确分割率,猪只个体98.37%的正确分割率,其中涉及爬跨行为的猪只分割准确率97.20%,猪只间粘连分割准确率97.22%。

(3)提取每个样本中像素面积的最小值生成爬跨行为分类的经验样本,选取5896为爬跨行为界定阈值,构成猪只爬跨行为分类器。该分类器在新的测试集上准确率为94.5%,证明分类器可用于猪只爬跨行为识别。

参 考 文 献

- [1] REINERS K, HEGGER A, HESSEL E F. Application of RFID technology using passive HF transponders for the individual identification of weaned piglets at the feed trough[J]. Computers and Electronics in Agriculture, 2009, 68(2): 178-184.
- [2] RINGGENBERG N, BERGERON R, DEVILLERS N. Validation of accelerometers to automatically record sow postures and stepping behaviour[J]. Applied Animal Behaviour Science, 2010, 128(1): 80-84.
- [3] MARTINEZ A M, FERNANDEZ C E, LOPEZ G B. Early detection of infection in pigs through an online monitoring system[J]. Transboundary and Emerging Diseases, 2015, 64(2): 364-373.
- [4] OTT S, MOONS C H. Automated video analysis of pig activity at pen level highly correlates to human observations of behavioural activities[J]. Livestock Science, 2014, 160: 132-137.
- [5] 陈紫城. 基于时空兴趣点的猪只行为识别[D]. 广州: 华南农业大学, 2016.
CHEN Zicheng. Pig behavior recognition based on Spatio-Temporal Interest Points [D]. Guangzhou: South China Agricultural University, 2016. (in Chinese)
- [6] 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 Qiumei, XIAO Deqin, ZHANG Genxing. Automatic pig drinking behavior recognition with machine vision [J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(6): 232-238. (in Chinese)
- [7] 李振晔. 运动目标检测跟踪技术在猪只行为监测中的应用研究[D]. 北京: 中国农业大学, 2013.
LI Zhenye. Study on moving object detection and tracking technology in the application of pig behavior monitoring [D]. Beijing: China Agricultural University, 2013. (in Chinese)
- [8] 纪滨, 朱伟兴, 刘波, 等. 基于脊腹线波动的猪只呼吸急促症状视频分析[J]. 农业工程学报, 2011, 27(1): 191-195.
JI Bin, ZHU Weixing, LIU Bo, et al. Video analysis for tachypnea of pigs based on fluctuating ridge-abdomen [J]. Transactions of the CSAE, 2011, 27(1): 191-195. (in Chinese)
- [9] 薛月菊, 朱勋沐, 郑婵, 等. 基于改进 Faster R-CNN 识别深度视频图像哺乳母猪只姿态[J]. 农业工程学报, 2018, 34(9): 189-196.
XUE Yueju, ZHU Xunmu, ZHENG Chan, et al. Lactating sow postures recognition from depth image of videos based on improved Faster R-CNN [J]. Transactions of the CSAE, 2018, 34(9): 189-196. (in Chinese)
- [10] VIAZZI S, ISMAYILOVA G. Image feature extraction for classification of aggressive interactions among pigs [J]. Computers and Electronics in Agriculture, 2014, 104: 57-62.
- [11] 吴燕. 基于星状骨架模型的猪只的跛脚识别[D]. 镇江: 江苏大学, 2014.
WU Yan. Detection of pig lame walk based on star skeleton model [D]. Zhenjiang: Jiangsu University, 2014. (in Chinese)
- [12] NASIRAHMADI A, OLIVER H. Automatic detection of mounting behaviours among pigs using image analysis [J]. Computers and Electronics in Agriculture, 2016, 124: 295-302.
- [13] KAIMING H, GKIOXARI G, DOLLAR P, et al. Mask R-CNN [C] // Proceedings of the IEEE International Conference on Computer Vision (ICCV). Italy, 2017, 2980-2988.
- [14] SHAOQING R, KAIMING H, 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, 2017, 39: 1137-1149.

- GUO Hao, MA Qin, ZHANG Shengli, et al. Prototype system of shape measurements of animal based on 3D reconstruction [J]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 45(5): 227–232. (in Chinese)
- [13] SALAU J, HAAS J H, JUNGE W, et al. A multi-Kinect cow scanning system; calculating linear traits from manually marked recordings of Holstein-Friesian dairy cows[J]. Biosystems Engineering, 2017, 157: 92–98.
- [14] 郭浩, 张胜利, 马钦, 等. 基于点云采集设备的奶牛体尺指标测量[J]. 农业工程学报, 2014, 30(5): 116–122.
GUO Hao, ZHANG Shengli, MA Qin, et al. Cow body measurement based on Xtion[J]. Transactions of the CSAE, 2014, 30(5): 116–122. (in Chinese)
- [15] SONG X, BOKKERS E A M, VANDERTOL P P J, et al. Automated body weight prediction of dairy cows using 3-dimensional vision[J]. Journal of Dairy Science, 2018, 101(5): 4448–4459.
- [16] SALAU J, HAAS J H, JUNGE W, et al. Automated calculation of udder depth and rear leg angle in Holstein-Friesian cows using a multi-Kinect cow scanning system[J]. Biosystems Engineering, 2017, 160: 154–169.
- [17] LE C Y, ALLAIN C, CAILLOT A, et al. High-precision scanning system for complete 3D cow body shape imaging and analysis of morphological traits[J]. Computers and Electronics in Agriculture, 2019, 157: 447–453.
- [18] 陈向阳, 杨洋, 向云飞. 欧氏聚类算法支持下的点云数据分割[J]. 测绘通报, 2017(11): 27–31.
CHEN Xiangyang, YANG Yang, XIANG Yunfei. Point cloud data segmentation supported by Euclidean clustering algorithm [J]. Bulletin of Surveying and Mapping, 2017(11): 27–31. (in Chinese)
- [19] 常鑫, 郎锐, 董建业. 基于移动网格点云精简算法的研究[J]. 测绘工程, 2018, 27(5): 17–22.
CHANG Xin, LANG Rui, DONG Jianye. Algorithm of point cloud simplification based on moving grid mesh [J]. Engineering of Surveying and Mapping, 2018, 27(5): 17–22. (in Chinese)
- [20] 傅思勇, 吴禄慎, 陈华伟. 空间栅格动态划分的点云精简方法[J]. 光学学报, 2017, 37(11): 253–261.
FU Siyong, WU Lushen, CHEN Huawei. Point cloud simplification method based on space grid dynamic partitioning [J]. Acta Optica Sinica, 2017, 37(11): 253–261. (in Chinese)
- [21] 王莹莹. 基于方向矢量曲率估算的点云精简研究[J]. 信息技术, 2015(6): 15–18.
WANG Yingying. Point cloud reduction research based on the normal vector curvature estimation[J]. Information Technology, 2015(6): 15–18. (in Chinese)
- [22] 张伟洁, 刘刚, 郭彩玲, 等. 基于三维点云的苹果树叶片三维重建研究[J]. 农业机械学报, 2017, 48(增刊): 103–109.
ZHANG Weijie, LIU Gang, GUO Cailing, et al. Apple tree leaf three-dimensional reconstruction based on point cloud[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(Supp.): 103–109. (in Chinese)
- [23] 杨秋翔, 王程远, 杨剑, 等. 基于法矢夹角的改进 ICP 算法[J]. 计算机工程与设计, 2016, 37(8): 2082–2086.
YANG Qiuxiang, WANG Chengyuan, YANG Jian, et al. Improved ICP algorithm based on normal vector [J]. Computer Engineering and Design, 2016, 37(8): 2082–2086. (in Chinese)
- [24] NIR O, PARMET Y, WERNER D, et al. 3D computer-vision system for automatically estimating heifer height and body mass [J]. Biosystems Engineering, 2018, 173: 4–10.
- [25] 刘凯, 夏苗, 杨晓梅. 一种平面点集的高效凸包算法[J]. 工程科学与技术, 2017, 49(5): 109–116.
LIU Kai, XIA Miao, YANG Xiaomei. An effective 2D convex hull algorithm[J]. Advanced Engineering Sciences, 2017, 49(5): 109–116. (in Chinese)
- [26] 牛金玉. 基于三维点云的奶牛体尺测量与体重预测方法研究[D]. 杨凌: 西北农林科技大学, 2018.
NIU Jinyu. Body size measurement and weight prediction for dairy cows based on 3D point cloud[D]. Yangling: Northwest A&F University, 2018. (in Chinese)

(上接第 266 页)

- [15] YI L, HAOZHI Q, JIFENG D, et al. Fully convolutional instance-aware semantic segmentation [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017, 4438–4446.
- [16] KAIMING H, XIANGYU Z, SHAOQING R, et al. Deep residual learning for image recognition [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, 770–778.
- [17] TSUNGYI L, PIOTR D, GIRSHICK R, et al. Feature pyramid networks for object detection [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017, 936–944.
- [18] TSUNGYI L, MICHAEL M, SERGE B, et al. Microsoft COCO: common objects in context [C] // European Conference on Computer Vision (ECCV), 2014, 740–755.
- [19] NOBUYUKI O. A threshold selection method from Gray-Level Histograms [J]. IEEE Transactions on Systems, Man, and Cybernetics, 1979, 9: 62–66.
- [20] CANNY J. A computational approach to edge detection [J]. IEEE Transactions on Pattern Analysis and Image Processing, 1986, 8(6): 679–698.
- [21] PAUL O, PAUL Z M. Direct and specific least-square fitting of hyperbolae and ellipses [J]. Journal of Electronic Imaging, 2004, 13(3): 492–503.