

基于时空信息融合的母猪哺乳行为识别

甘海明^{1,2} 薛月菊^{1,2} 李诗梅¹ 杨晓帆¹ 陈畅新¹ 区铭强¹

(1. 华南农业大学电子工程学院, 广州 510642; 2. 岭南现代农业科学与技术广东省实验室, 广州 510642)

摘要: 及时获取准确的母猪哺乳行为信息对提高猪只集中养殖效益至关重要。本文旨在建立深度学习网络, 融合时空信息, 实现自动识别母猪哺乳行为。识别过程主要分2个阶段: 母猪哺乳区域时空定位和哺乳区域时空信息特征提取、融合及识别。首先将俯拍视频图像序列输入 Mask R-CNN, ResNet-101+FPN 作为基础网络输出特征图输入区域生成网络, 生成母猪检测候选框并分别输入母猪姿态识别分支和关键点检测分支, 若母猪姿态被识别为侧卧则利用关键点检测分支输出关键点坐标, 确定母猪哺乳区域, 实现哺乳行为感兴趣时空区域定位。然后, 在感兴趣时空区域中, 利用双流卷积网络, 进行时间流和空间流特征提取。最后利用串接卷积融合方式, 识别序列图像中母猪是否进行哺乳。试验结果显示, 用于哺乳区域空间定位的关键点的综合召回率 R_k 和精准率 P_k 分别为 94.37% 和 94.53%, 母猪哺乳行为识别正确率为 97.85%, 灵敏度为 94.92%, 特异度为 98.51%。

关键词: 母猪; 哺乳行为; 关键点检测; 时空信息; 双流卷积网络

中图分类号: S828; TP391.41 文献标识码: A 文章编号: 1000-1298(2020)S1-0357-07

Automatic Sow Nursing Behaviour Recognition Based on Spatio-temporal Information Fusion

GAN Haiming^{1,2} XUE Yueju^{1,2} LI Shimei¹ YANG Xiaofan¹ CHEN Changxin¹ OU Mingqiang¹

(1. College of Electronic Engineering, South China Agricultural University, Guangzhou 510642, China

2. Guangdong Laboratory for Lingnan Modern Agriculture, Guangzhou 510642, China)

Abstract: Timely and accurate information on sow nursing behaviour in intensive pig industry is beneficial to efficient reproductive performance. The purpose was to establish deep-learning networks to recognize sow nursing behaviour automatically. The recognition was performed at two stages: nursing zone localization in temporal and spatial domain and nursing behaviour recognition using spatio-temporal information extraction and fusion. Firstly, video image sequences were input into Mask R-CNN, whose backbone ResNet-101+FPN generated feature maps and the feature maps were used to produce a set of regions of proposal that were fed into classification head and keypoints head, respectively. The classification head performed sow posture classification and sow detection and keypoint head detection of keypoints related to sow nursing zone extraction. If sow was classified as laterally lying, the keypoint detection results would remain or be filtered out. A sequence of extracted nursing zones were passed into following subnetwork. A self-adaptive nursing zone extraction method was proposed, according to the piglet's postpartum day and video recording height. Afterwards, within the spatio-temporal region of interest, spatio-temporal features were extracted by the temporal stream and spatial stream of the two-stream convolutional network, respectively. Convolutional features from the two streams were fused with combination of concatenation and convolution for final nursing recognition. Test results showed that the total keypoint detection recall R_k and precision P_k were 94.37% and 94.53%, respectively. Sow nursing behavior in long videos were recognized with an accuracy of 97.85%, a sensitivity of 94.92% and a specificity of 98.51%, which demonstrated the feasibility of automatic recognition of sow nursing behavior with computer vision.

Key words: sow; nursing behaviour; keypoint detection; spatio-temporal information; two-stream convolutional network

收稿日期: 2020-08-16 修回日期: 2020-09-18

基金项目: “十二五”国家科技支撑计划项目(2015BAD06B03-3)、广东省科技计划项目(2015A020209148)、广东省应用型科技研发项目(2015B010135007)和广州市科技计划项目(201605030013、201604016122)

作者简介: 甘海明(1995—),男,博士生,主要从事机器视觉与图像处理研究, E-mail: 444504196@163.com

通信作者: 薛月菊(1969—),女,教授,博士生导师,主要从事机器视觉与图像处理研究, E-mail: xueyueju@163.com

0 引言

仔猪的存活率关系到生猪养殖业的利益。营养缺乏或者饥饿是造成部分仔猪断奶前死亡的重要因素^[1],因此提高仔猪生存率可以着手于母猪哺乳阶段。母猪哺乳的频率和持续时间是判断其哺乳行为是否正常的重要依据^[2],也是母猪食物投喂量的关键参考之一^[3]。另外,哺乳频率也反映了母猪的情绪和健康状况,例如当母猪通过站立拒绝哺乳,表明母猪可能患有生理问题,如身体损伤或者身患疾病^[4]。因此,观察和分析母猪哺乳行为对猪只福利和生猪养殖业都有明显的积极意义,而人工观察和分析母猪的哺乳行为费时费力,鉴于此,本文建立基于计算机视觉的母猪哺乳行为自动识别网络,准确获取母猪哺乳行为信息。

近年来,自动识别动物行为成为计算机视觉领域的研究热点。CHEN等^[5]和LEE等^[6]基于图像分割技术识别猪只,进而检测猪只的攻击行为。两者的研究均依赖于高精度传统图像阈值分割。传统阈值分割对背景有严格要求,一般只适用于背景简单或者目标和背景颜色反差较明显的场景。本文中的视频是在较复杂的猪圈背景条件下拍摄的,并且猪只身上带有黑色斑块,其颜色与地面颜色相近,传统分割方法无法实现高精度分割,故不利于定位母猪哺乳区域。ZHU等^[7]通过检测猪嘴与饮水器之间的距离和持续时间,自动识别猪只的饮水行为。 TSAI等^[8]利用计算外接矩形边长实现牛的爬跨行为自动识别。NASIRAHMADI等^[9]利用检测猪只的椭圆面积识别猪只的爬跨行为。OCZAK等^[10]、VIAZZI等^[11]和LEE等^[6]通过获取猪只间的距离、运动速度和加速度等自动识别猪只的攻击行为。YANG等^[12]基于手工设计的运动特征联合支持向量机(Support vector machine, SVM)对母猪的哺乳行为进行检测。上述动物行为自动识别方法均基于几何特征(如位置、距离、面积等)或运动特征(如速度和加速度)实现,然而母猪的哺乳行为不只是母猪与仔猪之间的交互行为,还包括仔猪之间的互动行为,并不能通过简单的几何特征或运动特征组合进行表征,并且手工设计特征依赖于人的经验,需耗时试验确定最佳特征组合。

卷积神经网络(Convolutional neural network, CNN)是基于数据驱动机制训练的深度学习,可以自动提取图像特征,在行为识别中避免了依赖人的经验设计特征的过程^[13]。Mask R-CNN^[14]为多任务深度学习,能同时实现目标检测、分类和关键点检测。双流卷积网络^[15](Two-stream convolutional

network, TCN)能够较好地提取和融合时空特征,是一种常用的人类行为识别网络^[16-18]。因此,为解决复杂场景下母猪哺乳区域定位难,避免手工设计母猪哺乳行为识别的时空特征困难,本文采用Mask R-CNN识别母猪的姿态并检测母猪身体部位关键点,进而根据关键点确定哺乳区域,最后用双流卷积网络,融合哺乳区域的时空特征信息,对母猪哺乳行为进行识别。

1 材料与方法

1.1 数据获取

本文使用的哺乳期母猪视频采集于佛山市三水区某商业养殖场。研究对象为18头梅花母猪,其身体表面带有不均匀分布的黑色斑块,分别饲养在单独栏中并可自由活动,每栏面积约为3.8 m×2.0 m,每栏包含8~12头仔猪,日龄在2~21 d,几乎所有仔猪外表为纯黑色,部分仔猪为黑白杂色。拍摄相机固定于各栏中心正上方,镜头距离地面2.4~2.7 m,保证能拍摄到整个猪栏,通过改变拍摄高度来获取泛化性更强的数据。拍摄时间为07:00—18:00。所采用的视频帧率为5 f/s,分辨率为960像素×540像素。

1.2 关键点的选取与母猪姿态及行为定义

母猪的哺乳行为主要发生在其处于侧卧姿态时,并且本研究采用了俯拍方式获取视频数据,故只对处于侧卧姿态的母猪哺乳行为进行识别。因此,将母猪的姿态分为侧卧和非侧卧。经观察,哺乳区域主要分布在母猪前后腿之间,乳房区弧线以外向外延伸至仔猪体长的距离。为了确定该哺乳区域,特选定3个关键点辅助定位哺乳区域。母猪的侧卧姿态^[19]、哺乳行为^[20-21]和关键点 P_1 、 P_2 、 P_3 定义如表1所示,关键点的分布如图1所示。

表1 侧卧姿态、哺乳行为和关键点定义

Tab.1 Definition or description of laterally lying, nursing behavior and keypoints

| 项目 | 定义 |
|-------|-----------------------|
| 侧卧姿态 | 身体一侧与地面接触,四肢可见 |
| 哺乳行为 | 仔猪吮吸或推撞母猪乳房持续时间超过60 s |
| P_1 | 臀部弧线下端点 |
| P_2 | 乳房弧线中点 |
| P_3 | 前腿与身体连接处 |

1.3 数据集划分和标注

本文中的方法涉及了两个级联的卷积子网络,分别为Mask R-CNN和TCN,其输入信息的尺度不一致(Mask R-CNN的输入为图像帧,TCN的输入为视频片段),故设置两个训练数据集分别训练这2个子网络,2个测试数据集分别评价2个子网络,

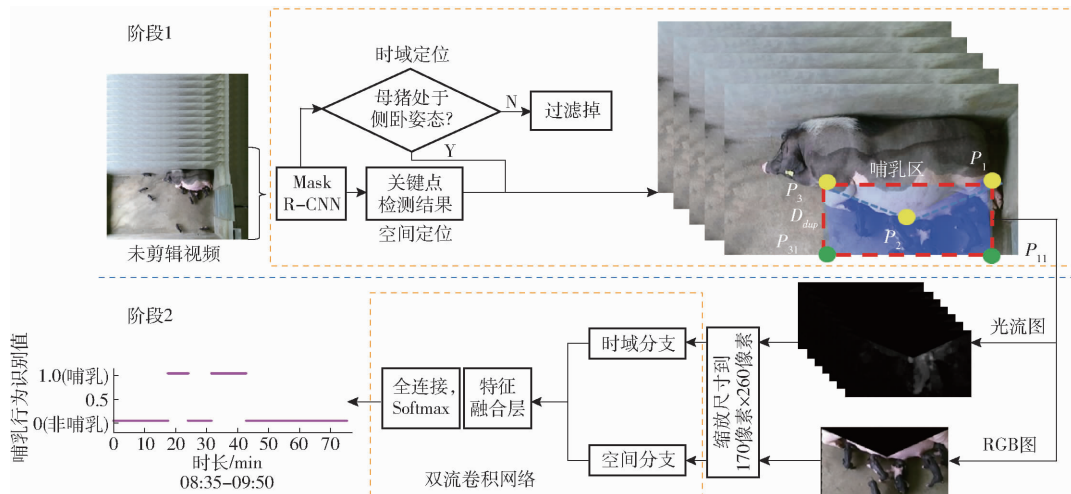


图 1 母猪哺乳行为自动识别方法流程图

Fig. 1 Pipeline of proposed method for sow nursing behavior recognition

1 个测试数据集综合评价本文方法。

18 个栏的视频数据随机排序并编号。第 1~11 栏划分为训练数据集。训练数据集 1 包含 20 040 帧视频图像(8 738 帧为侧卧,11 302 帧为非侧卧),用于训练母猪关键点检测和姿态识别网络(Mask R-CNN);训练数据集 2 包含 741 段视频片段(301 段包含哺乳行为,440 段不包含哺乳行为),用于训练 TCN,每段时长 60 s(300 帧),训练时每次随机连续采样 3 s(15 帧),母猪均处于侧卧姿态。

测试数据集 1、2 均来自第 12~16 栏。测试数据集 1 包含 5 550 帧视频图像(1 850 帧为侧卧,3 700 帧为非侧卧),用来评价母猪姿态识别效果,其中 1 850 帧母猪侧卧视频图像用来评价关键点检测效果;测试数据集 2 包含 1 551 段发生母猪哺乳

行为的视频片段和 4 089 段未发生母猪哺乳行为的视频片段,片段中母猪均处于侧卧姿态,每段时长 3 s(15 帧),用于评价 TCN 识别母猪哺乳行为的效果;测试数据集 3 为两段长视频,分别来自第 17、18 栏,时长均为 75 min。

除了哺乳行为,上述视频段中还包含了仔猪的其他日常行为,如相互追逐、攻击、推撞、攀爬、静睡等。2 个训练集均通过竖直翻转、水平翻转和 180° 旋转的方法扩增 4 倍以提升训练效果。具体数据集组成如表 2 所示。训练集 1 中母猪为侧卧姿态的图像标注为“1”,否则为“0”;训练集 2 中哺乳行为视频标注在动物学专家的指导下完成,带哺乳行为的视频片段标注为“1”,不带哺乳行为的视频片段标注为“0”;关键点用 Labelme 软件进行标注,以二维

表 2 训练数据集和测试数据集组成

Tab.2 Data allocation for training and test procedures

| 数据集 | 数据来源 | 图像/视频数量 | 总时长/min | 用途 |
|---------|---------|---|---------|------------------|
| 训练数据集 1 | 1~11 栏 | 20 040 帧图像 | 66.8 | 训练 Mask R-CNN |
| 训练数据集 2 | 1~11 栏 | 301 段包含哺乳行为视频,440 段不包含哺乳行为视频,每段时长 60 s | 741.0 | 训练 TCN |
| 测试数据集 1 | 12~16 栏 | 1 850 帧母猪侧卧图像,3 700 帧母猪非侧卧图像 | 18.5 | 评价关键点检测和母猪姿态识别效果 |
| 测试数据集 2 | 12~16 栏 | 1 551 段发生哺乳行为视频,4 089 段未发生母猪哺乳行为视频,每段时长 3 s | 282.0 | 评价哺乳视频片段识别效果 |
| 测试数据集 3 | 17、18 栏 | 2 段时长为 75 min 的视频 | 150.0 | 综合评价整体网络哺乳行为识别效果 |

坐标格式保存。

2 母猪哺乳行为识别方法

本研究的母猪哺乳行为自动识别分两阶段实现:感兴趣时空区域定位和基于时空信息特征融合的哺乳行为识别。由于本文只针对处于侧卧母猪的哺乳行为进行识别,因此需要在视频段中确定母猪处于侧卧姿态的区间,即时域定位;在确定母猪处于

侧卧姿态后,利用关键点检测结果确定母猪在视频图像中的哺乳区域,即空间定位,以排除哺乳区域以外猪只活动的干扰。若母猪的姿态识别为侧卧,则将连续 15 帧哺乳区域内的光流图像及中间帧对应的 RGB 图像分别输入双流卷积网络的时间流和空间流,提取时空特征信息并最后融合用于识别母猪的哺乳行为。母猪哺乳行为自动识别方法的流程图如图 1 所示。

2.1 感兴趣时空区域定位

2.1.1 母猪姿态识别和关键点检测

Mask R-CNN^[14] 主要由卷积层、最大池化层、正则化层、残差结构和全连接层组成。因此本文借鉴该网络模型,利用分类分支和关键点检测分支,识别母猪是否处于侧卧姿态,并检测其身体部位关键点,辅助提取哺乳区域。更深层的残差网络能提高关键点检测精度^[22],并且残差网络具有训练收敛快等特点^[23],因此选择 ResNet-101+FPN 作为基础网络,其生成的特征图输入候选框生成网络(Region proposal network, RPN)。训练过程中, RPN 对特征图生成系列候选框,引入分类损失 clc_{RPN} (目标或背景)和回归损失 reg_{RPN} ,候选框分别输入分类分支和关键点检测分支。分类分支判断候选框类别,即侧卧、非侧卧或背景,同时回归目标检测框坐标,分别产生分类损失 clc 和回归损失 reg ;关键点检测分支最后输出 3 幅关键点概率分布热图,分别对应 3 个关键点,引入关键点坐标回归损失 $loss_{kpt}$ 。对上述 5 个损失求和作为整个网络的监督信号,更新优化网络权值。Mask R-CNN 的关键点输出结果以二维坐标的形式保存,并映射到原图以提取母猪的哺乳区域。

本文的 Mask R-CNN 基于 Caffe2 完成训练,训练迭代次数共 1.7×10^5 次,初始学习率为 0.000 2, 80 000 次迭代后衰减为原来的 1/10,基础网络初始权值采用基于 ImageNet 的预训练模型权值,显卡型号为 NVIDIA GTX 980 TI。

2.1.2 自适应母猪哺乳区域检测

若母猪姿态被判别为侧卧,则保留对应图像的关键点检测结果,用于确定母猪哺乳区域。根据关键点分布结果(图 1),沿垂直于线段 P_1P_3 的方向,将线段 P_1P_3 向母猪体外平移,平移距离为 D_{dup} ,线段 P_1P_3 扫过的面积减去三角形 $P_1P_2P_3$ 面积即为母猪哺乳区域(即图 1 中浅蓝色多边形 $P_1P_2P_3P_{31}P_{11}$ 区域)。减去三角形 $P_1P_2P_3$ 的目的是减少母猪腹部与哺乳无关运动(如呼吸造成的腹部起伏)的影响。平移距离 D_{dup} 约等于仔猪体长以保证参与哺乳的仔猪均包含于哺乳区域内。由于同一哺乳区域尺寸会随拍摄高度和仔猪体长变化,而仔猪体长随着日龄 D_{pp} 增长而逐渐变长,因此为了建立自适应的母猪哺乳区域确定方式,从 18 栏视频图像中各随机抽取 50 帧进行统计分析,构建 D_{dup} 、 D_{pp} 和 D_{13} 之间的回归关系。

$$D_{dup} = 0.46D_{13} + 3.55D_{pp} - 42.31 \quad (1)$$

式中 D_{13} ——线段 P_1P_3 长度

通过旋转和双线性插值拉伸图像处理方法,将

所有提取到的哺乳区域转换为分辨率为 170 像素 \times 260 像素的图像序列。将图像序列按固定输入长度进行均分,得到若干训练样本用于训练 TCN。

2.2 时空信息融合

双流卷积网络主要由时间流和空间流两部分组成。空间流输入 RGB 图,负责提取物体的外观信息,如物体、场景等;而时间流输入若干连续光流图像负责捕获目标物体的运动信息^[24]。本文将用于输入时间流的若干连续光流图像称为光流栈(Optical flow stacking),光流栈长度用 L 表示。一般情况下,时空信息融合的方式主要有沿通道的特征图求和(Sum fusion)、串接融合(Concatenation fusion)和串接卷积融合(Concatenation convolution fusion)^[15]。试验证明串接卷积的性能往往优于其他融合方式^[15],故本文采用串接卷积的双流信息融合方式。本研究采用双流卷积网络结构如图 2 所示,Conv1_1、Conv1_2、Conv2_1、Conv2_2、Conv3 为卷积层,Concat 为沿通道特征图串接操作, 3×3 、 1×1 为卷积核的尺寸,16 和 32 为卷积层的输出通道数,Max Pooling 为最大池化层,Fc 为全连接层。首先利用 Lucas-Kanade 光流计算方法^[25]获取视频图像的光流序列。由哺乳区域割取的光流栈及中间帧对应的一幅 RGB 图像分别输入双流卷积网络中的时间流和空间流,时间流和空间流结构相同,均由两层卷积层和最大池化层组成,两个分支产生的特征图按通道拼接后,输入卷积核为 1×1 的卷积层,随后经最大池化层、两个全连接层和 Softmax 分类层,完成对哺乳行为的识别。

本文中训练 TCN 的迭代次数共 10 000 次,初始

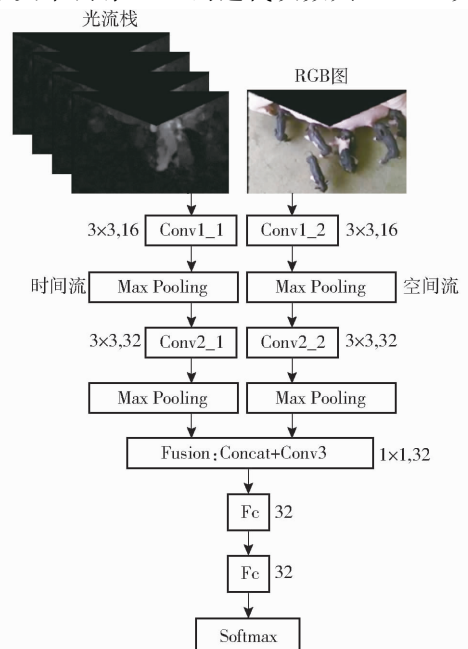


图 2 卷积双流网络结构图

Fig. 2 Structure of two-stream convolutional network

学习率为 0.000 2。训练采样方式为：随机选择一段视频中时刻 t 的 RGB 图像 I_t ，自 I_t 开始向前和向后各顺延选取 $(L-1)/2$ 帧光流图像，最终得到长度为 L 的光流栈 F_L ， I_t 和 F_L 构成时刻 t 的一个训练样本。

2.3 评价标准

本文采用正确率评价 Mask R-CNN 姿态识别效果。

$$A_{cc} = \frac{T_{PP} + T_{NP}}{S_{um_p}} \times 100\% \quad (2)$$

式中 T_{PP} 、 T_{NP} ——母猪姿态识别结果为真正类、真负类的样本数量

A_{cc} ——正确率

S_{um_p} ——母猪姿态识别测试样本总数

采用召回率 R_k 和精准率 P_k 评价 Mask R-CNN 的关键点检测效果。

$$R_k = \frac{T_{N_{kpt}}}{S_{um_{gt}}} \times 100\% \quad (3)$$

$$P_k = \frac{T_{N_{kpt}}}{S_{um_{det}}} \times 100\% \quad (4)$$

式中 $T_{N_{kpt}}$ ——正确检测的关键点总数

$S_{um_{gt}}$ ——测试集中真实标注的关键点总数

$S_{um_{det}}$ ——检测结果中关键点总数

本文约定以 D_{13} 真实长度为基准距离，检测结果中的关键点到对应真实关键点之间的距离小于 D_{13} 的 10% 则认为关键点被正确检测^[26-27]。

最后，采用正确率 A_{cc} 、灵敏度 S_e 和特异度 S_p 综合评价本研究方法识别母猪哺乳行为的效果。

$$S_e = \frac{T_p}{T_p + F_N} \times 100\% \quad (5)$$

$$S_p = \frac{T_N}{T_N + F_p} \times 100\% \quad (6)$$

式中 T_N 、 T_p 、 F_N 、 F_p ——哺乳行为识别结果中真负类、真正类、假负类和假正类的样本数量

3 结果与分析

3.1 母猪姿态识别和关键点检测结果

以 ResNet-101 作为基础网络的 Mask R-CNN 的姿态检测结果如表 3 所示，正样本（侧卧）的识别正确率为 98.51%，负样本（非侧卧）的识别正确率为 97.33%，其综合正确率为 97.71%，正样本识别正确率比负样本识别正确率高 1.18 个百分点。试验结果表明母猪侧卧姿态比非侧卧姿态更容易识别，这可能是因为侧卧姿态较非侧卧姿态的外观表征差异较大，非侧卧包含了多种其他姿态，如腹卧、站立等。姿态识别误差主要发生在母猪姿态发生转

换时，此时姿态分界不明显。

表 3 母猪姿态识别结果

Tab. 3 Results of sow posture recognition

| 识别结果 | 真实值/帧 | | 总和/帧 |
|-------|-------|-------|-------|
| | 侧卧 | 非侧卧 | |
| 侧卧 | 1 822 | 99 | 1 921 |
| 非侧卧 | 28 | 3 601 | 3 629 |
| 总和 | 1 850 | 3 700 | 5 550 |
| 正确率/% | 98.51 | 97.33 | 97.71 |

表 4 为各关键点检测结果， P_1 、 P_2 和 P_3 的检测综合召回率 R_k 和精准率 P_k 分别为 94.37% 和 94.53%。 P_2 的召回率和精准率在 3 个关键点中最低，可能是因为 P_2 位于母猪乳房弧线中点，较另外两点不容易特征化，故导致 P_2 对应的关键点输出通道输出的概率分布较其他两个关键点发散，增加其定位的不确定性。而 P_1 和 P_3 位于母猪的四肢关节处，此处有明显的曲线角点，几何特征明显，容易在图像中识别。另外，仔猪攀爬母猪身体使关键点被遮挡时也会导致关键点检测失败。

表 4 关键点检测结果

Tab. 4 Results of keypoint detection %

| 指标 | P_1 | P_2 | P_3 | 综合 |
|-------|-------|-------|-------|-------|
| R_k | 95.75 | 92.42 | 94.95 | 94.37 |
| P_k | 95.91 | 92.57 | 95.11 | 94.53 |

3.2 哺乳区域提取效果

本文提出了一种自适应的母猪哺乳区域提取方法。图 3 展示了 4 种场景下关键点（黄色点）检测和哺乳区（浅绿色区域）的提取效果。检测效果表明 Mask R-CNN 在关键点检测方面具有较强的鲁棒性，受目标部分缺失、光源和背景的干扰较小，能适应不同场景的拍摄高度及不同仔猪体长成功提取到的哺乳区域，保证参与哺乳行为的仔猪基本包含于哺乳区内，提高了本文母猪哺乳行为识别方法的适用性。




图 3 4 种场景下关键点检测效果

Fig. 3 Keypoint detection results at four different scenes

3.3 母猪哺乳行为识别结果

试验结果表明,当 L 为15帧时,母猪哺乳行为识别准确率最高,因此本文试验固定光流栈的长度为15帧。试验结果如表5所示,正确率为93.95%,灵敏度为94.13%,特异度为93.89%。根据母猪哺乳行为的定义,哺乳行为至少需持续60s,在长视频测试集中,根据检测结果的持续时长过滤掉不符合哺乳行为定义的结果。因此,从第17、18栏中各挑选1段上午和下午时长75min的长视频段识别视频中母猪的哺乳行为,以综合评价本文哺乳行为识别方法的不同时段的识别效果。最终母猪哺乳行为识别结果如图4所示。两段长视频的识别结果为正确率97.85%,灵敏度94.92%,特异度98.51%。




图4 长视频段中母猪哺乳行为识别结果

Fig. 4 Sow nursing behavior recognition results in long videos

泛化能力,能够适应不同场景。值得注意的是,在识别过程中,哺乳区域错误地提取到哺乳区域以外区域对非哺乳行为的识别影响较小,这是因为哺乳区域以外不存在哺乳行为。本文深度网络模型的总规模为638.7MB,识别速度为7.2f/s,高于视频帧率。

4 结束语

基于Mask R-CNN识别母猪姿态,检测母猪身

表5 短视频的哺乳行为识别结果混淆矩阵
Tab. 5 Confusion matrix of sow nursing behavior recognition results in short video clips

| 参数 | 真实值/段 | | 总和 |
|--------|-------|-------|-------|
| | 哺乳 | 非哺乳 | |
| 识别结果/段 | 哺乳 | 1 460 | 1 710 |
| | 非哺乳 | 91 | 3 930 |
| 总和 | 1 551 | 4 089 | 5 640 |
| 正确率/% | 94.13 | 93.89 | 93.95 |

从图4中可以看出,在不同时段本文的母猪哺乳行为识别方法均达到较高的准确度。在图4a中约从第11min开始出现识别错误,这些错误可能由阳光照射造成光流计算质量下降引起。就两栏的识别效果而言,总体识别结果的准确度较高,说明本文提出的母猪哺乳行为识别方法具有较强的鲁棒性和

体部位3个关键点以辅助自适应提取母猪哺乳区域,然后利用双流卷积网络融合哺乳区域的时空信息,识别母猪哺乳行为。提出了自适应的母猪哺乳区域提取方法,能适应不同拍摄高度及不同日龄仔猪,提高了本文算法的适用性。本文算法识别结果为:正确率97.85%,灵敏度94.92%,特异度98.51%。结果表明,基于计算机视觉技术自动识别母猪哺乳行为是可行的。

参 考 文 献

- [1] ISON S H, JARVIS S, ASHWORTH C J, et al. The effect of post-farrowing ketoprofen on sow feed intake, nursing behaviour and piglet performance[J]. *Livestock Science*, 2017, 202: 115 - 123.
- [2] VALROS A E, RUNDGREN M, SPINKA M, et al. Nursing behaviour of sows during 5 weeks lactation and effects on piglet growth[J]. *Applied Animal Behaviour Science*, 2002, 76(2): 93 - 104.
- [3] VAN DEN BRAND H, SCHOUTEN W G P, KEMP B. Maternal feed intake, but not feed composition affects postural behaviour and nursing frequency of lactating primiparous sows[J]. *Applied Animal Behaviour Science*, 2004, 86(1): 41 - 49.
- [4] FRASER D. The nursing posture of domestic sows and related behaviour[J]. *Behaviour*, 1976, 57: 51 - 63.
- [5] CHEN C, ZHU W X, MA C H, et al. Image motion feature extraction for recognition of aggressive behaviors among group-housed pigs[J]. *Computers and Electronics in Agriculture*, 2017, 142: 380 - 387.
- [6] LEE J, JIN L, PARK D, et al. Automatic recognition of aggressive behavior in pigs using a Kinect depth sensor[J]. *Sensors*, 2016, 16(5): 631 - 641.
- [7] ZHU W X, GUO Y Z, JIAO P P, et al. Recognition and drinking behaviour analysis of individual pigs based on machine vision[J]. *Livestock Science*, 2017, 205: 129 - 136.
- [8] TSAI D M, HUANG C Y. A motion and image analysis method for automatic detection of estrus and mating behavior in cattle[J]. *Computers and Electronics in Agriculture*, 2014, 104: 25 - 31.
- [9] NASIRAHMADI A, HENSEL O, EDWARDS S A, et al. Automatic detection of mounting behaviours among pigs using image analysis[J]. *Computers and Electronics in Agriculture*, 2016, 124: 295 - 302.

- [10] OCZAK M, VIAZZI S, ISMAYILOVA G, et al. Classification of aggressive behaviour in pigs by activity index and multilayer feed forward neural network[J]. *Biosystems Engineering*, 2014, 119: 89 – 97.
- [11] VIAZZI S, ISMAYILOVA G, OCZAK M, et al. Image feature extraction for classification of aggressive interactions among pigs [J]. *Computers and Electronics in Agriculture*, 2014, 104: 57 – 62.
- [12] YANG A, HUANG H, ZHENG B, et al. An automatic recognition framework for sow daily behaviours based on motion and image analyses[J]. *Biosystems Engineering*, 2020, 192: 56 – 71.
- [13] REICHSTEIN M, CAMPS-VALLS G, STEVENS B, et al. Deep learning and process understanding for data-driven earth system science[J]. *Nature*, 2019, 566(7743): 195 – 204.
- [14] HE K, GKIOXARI G, DOLLÁR P, et al. Mask R – CNN[J]. *arXiv*, 2018: 1703.06870v3.
- [15] FEICHTENHOFER C, PINZ A, ZISSERMAN A. Convolutional two-stream network fusion for video action recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1933 – 1941.
- [16] BHATTACHARJEE P, DAS S. Two-stream convolutional network with multi-level feature fusion for categorization of human action from videos[C] // *Pattern Recognition and Machine Intelligence*, 2017: 549 – 556.
- [17] WANG X H, GAO L L, WANG P, et al. Two-stream 3-D convNet fusion for action recognition in videos with arbitrary size and length[J]. *IEEE*, 2018, 20(3): 634 – 644.
- [18] ZHU Y, LAN Z, NEWSAM S, et al. Hidden two-stream convolutional networks for action recognition[J]. *arXiv preprint arXiv*, 2017: 1704.00389v4.
- [19] LOU Z, HURNIK J F. Peripartum sows in three farrowing crates: posture patterns and behavioural activities [J]. *Applied Animal Behaviour Science*, 1998, 58(1): 77 – 86.
- [20] VALROS A, RUNDGREN M, SPINKA M, et al. Metabolic state of the sow, nursing behaviour and milk production [J]. *Livestock Production Science*, 2003, 79(2 – 3): 155 – 167.
- [21] CHIDGEY K L, MOREL P C H, STAFFORD K J, et al. Sow and piglet behavioral associations in farrowing pens with temporary crating and in farrowing crates[J]. *Journal of Veterinary Behavior-Clinical Applications and Research*, 2017, 20: 91 – 101.
- [22] GIRDHAR R, GKIOXARI G, TORRESANI L, et al. Detect-and-track; efficient pose estimation in videos [C] // *IEEE*, 2018: 350 – 359.
- [23] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // *IEEE*, 2016: 770 – 778.
- [24] SIMONYAN K, ZISSERMAN A. Two-stream convolutional networks for action recognition in videos [J]. *arXiv preprint arXiv*, 2014: 1406.2199v2.
- [25] LUCAS B, KANADE T. An iterative image registration technique with an application to stereo vision [C] // *DARPA Image Understanding Workshop*, 1981, 121: 130.
- [26] ANDRILUKA M, PISHCHULIN L, GEHLER P, et al. 2D human pose estimation; new benchmark and state of the art analysis [C] // 2014 IEEE Conference on Computer Vision and Pattern Recognition, 2014: 3686 – 3693.
- [27] YANG Y, RAMANAN D. Articulated human detection with flexible mixtures of parts [J]. *IEEE*, 2013, 35(12): 2878 – 2890.

(上接第 266 页)

- [20] SHIN J Y, HEO J H, JEONG C, et al. Meta-heuristic maximum likelihood parameter estimation of the mixture normal distribution for hydro-meteorological variables [J]. *Stochastic Environmental Research and Risk Assessment*, 2014, 28(2): 347 – 358.
- [21] 杨子涵, 宋正河, 尹宜勇, 等. 基于 POT 模型的大功率拖拉机传动轴载荷时域外推方法 [J]. *农业工程学报*, 2019, 35(15): 40 – 47.
YANG Zihan, SONG Zhenghe, YIN Yiyong, et al. Time domain extrapolation method for load of drive shaft of high-power tractor based on POT model [J]. *Transactions of the CSAE*, 2019, 35(15): 40 – 47. (in Chinese)
- [22] 成凯, 张盾. 推土机车架纵梁程序加载载荷谱的编制 [J]. *农业工程学报*, 1997, 13(4): 40 – 45.
CHENG Kai, ZHANG Dun. The program of load spectrum applying on lengthwise beam of dozer frame [J]. *Transactions of the CSAE*, 1997, 13(4): 40 – 45. (in Chinese)
- [23] 翟新婷, 张晓晨, 江柱锦, 等. 基于混合分布的轮式装载机半轴载荷谱编制 [J]. *农业工程学报*, 2018, 34(8): 78 – 84.
ZHAI Xinting, ZHANG Xiaochen, JIANG Zhujin, et al. Load spectrum compiling for wheel loader semi-axle based on mixed distribution [J]. *Transactions of the CSAE*, 2018, 34(8): 78 – 84. (in Chinese)
- [24] WANG Jixin, CHEN Hongbin, LI Yan, et al. A review of the extrapolation method in load spectrum compiling [J]. *Strojniški Vestnik-Journal of Mechanical Engineering*, 2016, 62(1): 60 – 75.
- [25] 高云凯, 徐成民, 方剑光. 车身台架疲劳试验程序载荷谱研究 [J]. *机械工程学报*, 2014, 50(4): 92 – 98.
GAO Yunkai, XU Chengmin, FANG Jianguang. Study on the programed load spectrum of the body fatigue bench test [J]. *Journal of Mechanical Engineering*, 2014, 50(4): 92 – 98. (in Chinese)