

# 基于 DeepLabCut 算法的猪只体尺快速测量方法研究

赵宇亮 曾繁国 贾楠 朱君 王海峰 李斌

(北京市农林科学院智能装备技术研究中心,北京 100097)

**摘要:**为解决基于计算机视觉猪只体尺测量过程中存在的对猪只姿态依赖度高、测定效率低等问题,提出了一种基于 DeepLabCut 算法的非接触式猪只体尺快速测量方法。本研究以长白猪为研究对象,使用 RealSense L515 深感相机作为图像数据采集单元获取猪只背部 RGB-D 数据,通过分析对比 ResNet、MobileNet-V2、EfficientNet 系列的 10 个主干网络训练效果,选取 EfficientNet-b6 模型作为 DeepLabCut 算法最优主干网络进行猪只体尺特征点检测;为实现猪只体尺数据的精准计算,本文采用 SVM 模型识别猪只站立姿态,筛选猪只自然站立状态;在此基础上,采用深度数据临近区域替换算法对离群特征点进行优化,并计算猪只体长、体宽、体高、臀宽和臀高 5 项体尺指标。经对 140 组猪只图像进行测试发现,本研究提出的算法可实现猪只自然站立姿态下体尺的实时、精准测量,体尺最大均方根误差为 1.79 cm,计算耗时为每帧 0.27 s。

**关键词:**猪只; DeepLabCut; 非接触式; 特征点; 体尺测量

中图分类号: TP391.41 文献标识码: A 文章编号: 1000-1298(2023)02-0249-07

OSID:



## Rapid Measurements of Pig Body Size Based on DeepLabCut Algorithm

ZHAO Yuliang ZENG Fanguo JIA Nan ZHU Jun WANG Haifeng LI Bin

(Intelligent Equipment Research Center, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China)

**Abstract:** At present, the computer vision-based pig body measurement shows a high dependence on pig posture and low measurement efficiency. To solve these problems, a rapid and non-contact pig body size measurement method based on DeepLabCut was proposed. The top view RGB-D images of landrace pigs were captured by a RealSense L515 camera. The training effects of 10 backbone networks of ReNet, MobileNet-V2, and EfficientNet series were compared and analyzed, and then the EfficientNet-b6 model was selected as the optimal backbone network of DeepLabCut algorithm for feature point detection of pig body size. In order to achieve accurate calculation of pig body size data, SVM model was used to identify the standing stance of pigs and screen the natural standing stance of pigs. Based on this, the depth-valued proximity region replacement algorithm was used to optimize the outlier feature points and calculate the five body size indexes of pig body length, body width, body height, rump width and rump height by Euclidean distance. This method was tested on 140 groups of standing images of pigs, and it was found that the algorithm could achieve real-time and accurate measurement of body size in the natural standing posture of pigs, with maximum root mean square error of 1.79 cm and computation time of 0.27 s per frame.

**Key words:** pig; DeepLabCut; non-contact; feature point; body size measurement

## 0 引言

猪只体尺参数是衡量其生长状况的主要指

标<sup>[1-3]</sup>,在种猪选育、肉质评价、精准饲喂和分群管理中起着重要作用<sup>[4-7]</sup>。一般来讲,体尺参数主要包括体长、体宽、体高、臀宽和臀高 5 项指标。目前,

猪只体尺测量主要采用人工测量方式进行。人工测量往往需要借助测杖、圆形测定器和卷尺等工具测定,费时费力,而且易引起猪只应激反应,测量精度难以保证。非接触式猪只体尺测量方法成为科研人员的重要探索方向。近年来,基于计算机视觉的非接触式测量技术经历了“平面图像—立体视觉”和“人工特征工程—自动特征工程”的发展阶段<sup>[8-10]</sup>。在猪只体尺测量方面,DESHAZER 等<sup>[11]</sup>于 1988 年首次提出将计算机成像系统用于猪只体尺测量研究;WHITE 等<sup>[12]</sup>、DOESCHL-WILSON 等<sup>[13]</sup>于 2004 年分别采用单目相机开展了猪只生长过程的彩色图像采集和体尺指标计算研究,但猪舍环境、猪体脏污和地面高光反射等问题影响轮廓提取,测量精度有待提高<sup>[14]</sup>;2019 年前后,PEZZUOLO 等<sup>[15]</sup>、司永胜等<sup>[16]</sup>基于 Kinect 深度相机采集猪只理想姿态下的背部图像,通过特征点检测来计算猪只体尺参数,但图像预处理过程繁琐<sup>[17]</sup>,无法实现实时测量;近年来,DeepPose<sup>[18]</sup>、DeeperCut<sup>[19]</sup>、ArtTrack<sup>[20]</sup>、OpenPose<sup>[21]</sup>等姿态检测算法在人体姿态实时估计方面的应用成为研究热点,但前期需要大量标注数据集(5 000 幅以上)进行模型训练,数据标注过程费时费力。2018 年,MATHIS 等<sup>[22]</sup>提出了一种基于深度神经网络迁移学习的无标记姿态估计算法(DeepLabCut),该算法只需少量数据集(约 200 幅)进行训练,已在老鼠<sup>[23]</sup>、灵长动物<sup>[24]</sup>、猎豹<sup>[25]</sup>和赛马<sup>[26]</sup>等多个物种的姿态实时跟踪方面呈现良好的检测性能,但在猪只姿态检测及体尺测量方面尚未有研究报道。

基于此,为实现猪只养殖过程中体尺参数的非接触式快速准确测量,本文使用 RealSense L515 深感相机采集猪只站立姿态图像,借助 DeepLabCut 算法处理猪只背部 RGB 图像并提取关键特征点,开展 5 项体尺参数的测量研究。

## 1 数据集与测量方法

### 1.1 平台搭建

猪只体尺数据采集平台结构示意图如图 1 所示。在猪只保育床(尺寸为 1.8 m × 1.8 m)正上方 2 m 处安装 RGB-D 图像采集平台。该平台主要由深度数据采集单元、微型边缘计算单元、电子秤、无线局域网和计算机工作站组成。深度数据采集单元选用 Intel RealSense L515 深感相机,内置 RGB 图像传感器(分辨率为 1 920 像素 × 1 080 像素,帧率为 50 f/s)、深度传感器(分辨率为 1 024 像素 × 768 像素,帧率为 30 f/s)和 BMI085 惯性测量单元,探测范围 0.25 ~ 9 m,RGB 视场 70° × 43°,深度视场 70° ×

55°。微型边缘计算单元选用 NVIDIA Jetson Xavier NX 开发者套件,内置 384 个 NVIDIA CUDA Cores、48 个 Tensor Cores、6 块 Carmel ARM CPU 和 2 个 NVIDIA 深度学习加速器引擎,可支持 RealSense L515 深感相机的数据采集、模型部署、多算法融合运算等功能。在前期数据收集过程中,为有效采集猪只站立图像,本研究采用电子秤(精度 0.1 kg,广东寮步益科电子公司)进行辅助判断,当边缘计算单元获取的电子秤称取的猪只实时体质量数据波动小于 0.2 kg 并持续 3 s 以上时,开启并采集猪只 RGB-D 图像。

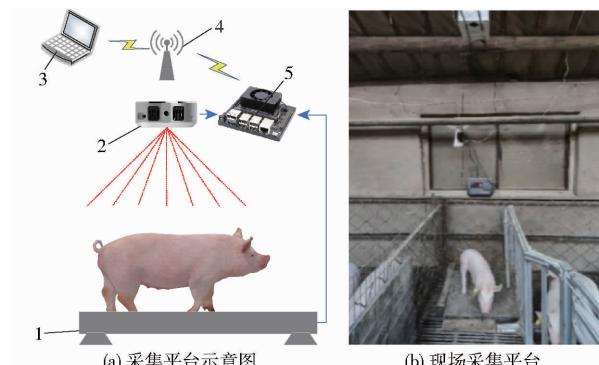


图 1 数据采集平台

Fig. 1 Data acquisition platform

1. 电子秤 2. 深度数据采集单元 3. 计算机工作站 4. 无线局域网 5. 微型边缘计算单元

### 1.2 数据获取

本试验于 2021 年 4 月 1 日至 6 月 15 日在河北省秦皇岛明霞养殖场某一单栏中进行(图 1b),猪只品种为长白,数量为 12 头,日龄为 30 ~ 115 d,体质量为 6 ~ 50 kg。基于数据采集平台,共获取单体猪只站立图像 700 组用于模型训练与测试。

### 1.3 体尺自动测量方法

#### 1.3.1 测量算法

本研究首先参考猪只体尺测量点的位置,在猪只图像中选取关键特征点,并进行图像特征点标记和模型训练,验证特征点检测效果;其次,结合深感相机内参数,计算关键特征点世界坐标并优化离群特征点;然后,计算猪只 5 项体尺参数。具体算法如图 2 所示。

#### 1.3.2 背部特征点选择

借助传统人工体尺测量方法,观察并选择猪只图像中 10 个特征点进行标记,用于后续模型训练。如图 3 所示,B 为猪只尾根区域位置,L<sub>1</sub>、R<sub>1</sub> 为猪只肩部区域最宽处左、右两个区域位置,L<sub>2</sub>、R<sub>2</sub> 为猪只臀部最宽处左、右两个区域位置,E<sub>l</sub> 为猪只左耳尖位置,E<sub>r</sub> 为猪只右耳尖位置,F 为颈部中点位置,M 为猪只臀部最宽处中心点位置,N 为猪只肩部区域最

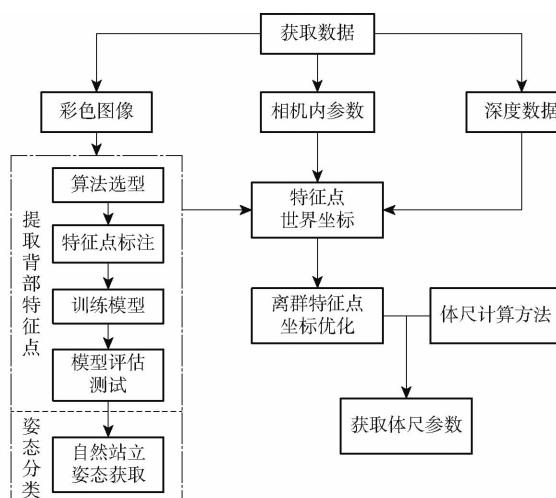


图2 猪只体尺测量算法流程图

Fig. 2 Flow chart of pig body size measurement algorithm

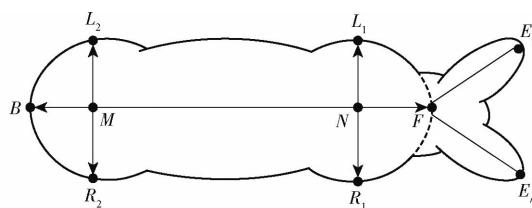


图3 猪只背部特征点标记示意图

Fig. 3 Schematic of key points marking on back of pigs

宽处中心点位置。

### 1.3.3 特征点提取算法

为自动提取猪只背部特征点位置,本研究选取 DeepLabCut 算法开展猪只背部特征点检测研究。DeepLabCut 算法是一个结合对象识别和语义分割算法的深度卷积网络结构。以 ResNet 作为 DeepLabCut 主干网络结构为例,其具体实现算法是:在原有基础网络上去除 ResNet 残差网络结构分类层,接入反卷积层进行上采样,获得载有特征点分布情况的特征图,并以特征点概率密度状况及向量趋势数据呈现,进而确定特征点具体位置,得到该特征点的图像坐标,具体流程如图 4 所示。接下来,运用已采集的批量猪只图像数据按照上述流程对 DeepLabCut 网络进行训练,得到猪只各特征点的分布情况,如图 5 所示,特征数据以热力图形式映射在原始图像中。

为获得猪只背部特征点检测最优模型,本研究选取 ResNet - 50、ResNet - 101、ResNet - 152、MobileNet - V2 - 1.0、MobileNet - V2 - 0.75、MobileNet - V2 - 0.5、MobileNet - V2 - 0.35、EfficientNet - b0、EfficientNet - b3 和 EfficientNet - b6 共 10 个网络模型<sup>[27-30]</sup> 进行训练并择优作为 DeepLabCut 主干网络模型。

### 1.3.4 站立姿态分类

由于猪只身体处于卷曲、头部摆动等非自然站

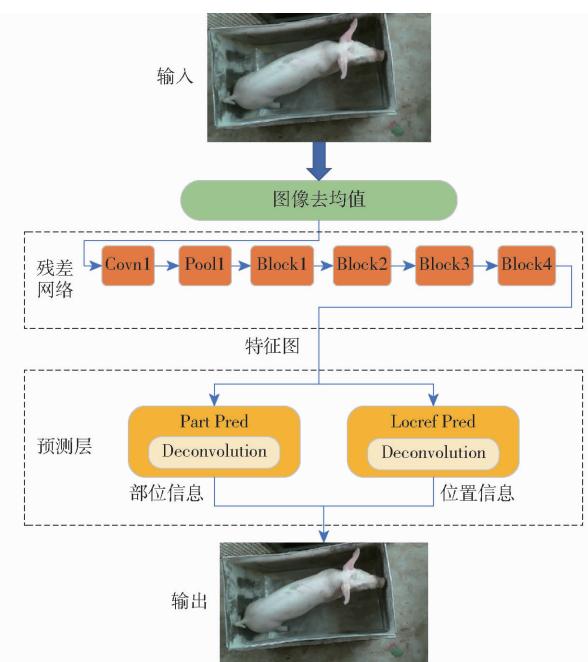


图4 网络模型结构图

Fig. 4 Network model structure diagram

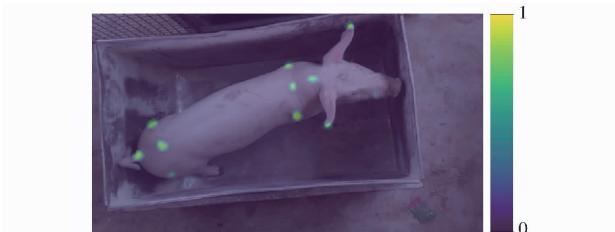


图5 特征位置分布图

Fig. 5 Feature location distribution map

立姿态时,体尺测量会产生较大误差,因此,为实现猪只 5 项体尺数据精准计算,在获得猪只特征点信息后,需筛选猪只自然站立姿态进行体尺测量。一般自然站立状态下, $E_i$  与  $E_r$  连线  $S_1$ ,  $L_1$  与  $R_1$  连线  $S_2$ ,  $L_2$  与  $R_2$  连线  $S_3$ , 这 3 条线间近似平行,各直线间夹角比较小;非自然站立状态下,由于头部或身体扭曲,各直线间夹角比较大。

本文在得到多组 3 条线间的夹角数据后 (Angle\_S12、Angle\_S23、Angle\_S13), 运用支持向量机 (Support vector machine, SVM) 进行模型训练。SVM 分类的主要思想是通过核函数定义的非线性变换将输入空间变换成一个高维空间, 并在这个空间中寻找一个分类超平面作为决策平面, 使得正例和反例之间的隔离边缘被最大化。本文将数据集主要分成两类(自然站立状态与非自然站立状态), 如图 6 所示。选用径向基函数 (Radial basis function) 作为 SVM 核函数, 在姿态模型训练过程中主要涉及惩罚系数与 gamma 两个参数。其中惩罚系数即对误差的宽容度, 惩罚系数越高, 说明越不能容忍出现误差, 容易过拟合; 惩罚系数越小, 容易欠拟合。

gamma 值隐含地决定了数据映射到新的特征空间后的分布, gamma 值越大, 支持向量越少, gamma 值越小, 支持向量越多。在模型训练过程需要调节这两个参数,使得姿态分类模型准确率高又具备较强的泛化能力。

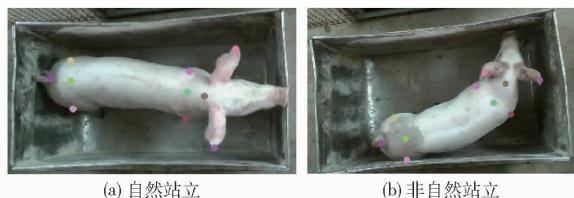


图 6 不同状态站立图像

Fig. 6 Standing images in different states

### 1.3.5 3D 坐标转换

为获得原始数据中彩色图像与深度图像的坐标间映射关系,本研究采用 Intel RealSense 提供的 pyrealsense2 工具包进行图像配准,实现目标区域由像素坐标向世界坐标的转换。具体转换关系如图 7 所示,世界坐标( $X, Y, Z$ )变换计算公式为

$$\begin{cases} X = \frac{(u - c_x) d(u, v)}{f_x} \\ Y = \frac{(v - c_y) d(u, v)}{f_y} \\ Z = d(u, v) \end{cases} \quad (1)$$

式中  $c_x$ ——图像中心点横像素坐标,像素

$c_y$ ——图像中心点纵像素坐标,像素

$f_x$ ——横向像素焦距,像素

$f_y$ ——纵向像素焦距,像素

$d(u, v)$ ——图像点( $u, v$ )深度,m

本文深度相机  $c_x = 948.963$  像素,  $c_y = 524.896$  像素,  $f_x = 1371.98$  像素,  $f_y = 1372.58$  像素。

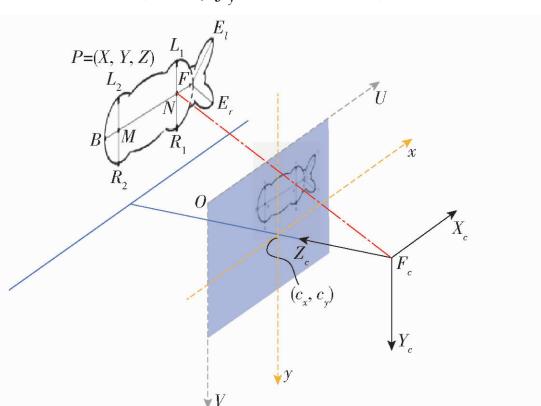


图 7 图像坐标与世界坐标转换关系

Fig. 7 Image coordinate and world coordinate conversion diagram

### 1.3.6 离群特征点坐标优化

实际应用中,由于 RealSense L515 自身激光扫描方式特点,部分深度信息会存在丢失情况,尤其是

猪只边缘与地面交接处的深度数据丢失更为严重,还有通过 DeepLabCut 算法获取的靠近身体边缘区域特征点的微小偏差都会造成猪只体尺的大幅误差。

已知摄像头与地面距离,易将深度信息划分为地面区域  $G$ 、猪体区域  $B$ 、未获取深度区域  $O$ 。如图 8 所示,图 8a 通过带通分割方式将深度图分成 3 个区域,红色为猪体区域,绿色为地面区域,蓝色为未得到深度数据区域。通过 DeepLabCut 算法得到特征点的图像位置与真实标记位置无明显差异,将特征点以 3D 形式呈现,明显看出点  $E_1, B$  深度为 0 mm,点  $L_1$  映射在地面区域。因此需要对离群点位置进行优化,从而计算猪只体尺数据。

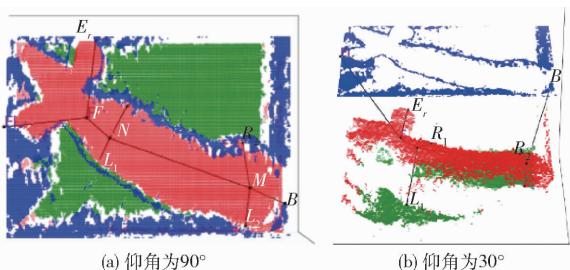


图 8 深度数据不同仰角 3D 图

Fig. 8 3D diagrams of depth data at different elevation angles

为解决这一问题,本研究设计了一种离群特征点临近区域深度替换算法。对于离群特征点  $P$ ,在深度图上以该点图像坐标位置作为中心点,向外扩张成  $(2d+1) \times (2d+1)$  像素矩阵区域,获取该区域深度数据集合,将点  $P$  的深度数据替换成该集合非零最小值。本文选用矩形区域中非零最小值与矩形区域非零平均值对比测试,最终选择矩形区域非零最小值替代离群点深度,此方式相对于矩形区域非零平均值替代方法更符合实际测量点位置。

### 1.3.7 体尺计算

获得猪只背部各特征点世界坐标以后,计算猪只体长(从点  $F$  到点  $B$  猪体背脊曲线长度)、体宽( $L_1$  与  $R_1$  直线距离)、臀宽( $L_2$  与  $R_2$  直线距离)、体高(点  $N$  距地面高度)和臀高(点  $M$  距地面高度)。其中猪只体长为颈部中点到尾跟点间的脊背曲线长度,即图 9 所示蓝色曲线长度。需对蓝色区域经过的离散点世界坐标进行多项式函数拟合,应用弧微分法计算该曲线长度。

## 2 结果与讨论

### 2.1 模型训练与评估

为了对 DeepLabCut 算法中的网络模型进行训练,同时评估 10 个主干网络模型的运算速度与准确度,针对模型进行离线训练与测试,试验环境:Intel

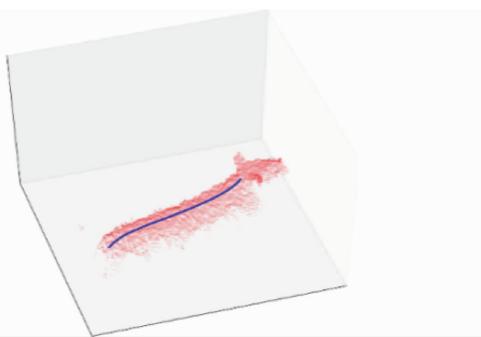


图 9 猪只体长曲线提取效果图

Fig. 9 Pig body length curve extraction effect

Core i9-10900X 型号 CPU, TITAN RTX 型号 GPU, Ubuntu 18.04 操作系统, Python 3.7 编程语言。

为了量化基于 DeepLabCut 算法的特征点检测方法针对小样本量数据模型训练效果和预测能力, 随机抽取 150 幅图像进行标记, 将图像数据集随机分成训练集和测试集(分别为 80% 和 20%), 并在测试图像上评估 DeepLabCut 的性能模型。训练过程中选取 Adam 优化器, 设置批处理为 1 幅, 学习率为 0.02, 迭代次数为 50 000 次。

10 个主干网络模型训练过程的 Loss 曲线如图 10 所示。由图可知, 10 个模型在迭代 40 000 次时均收敛, 且网络损失值由小到大呈现为 EfficientNet 系列、ResNet 系列、MobileNet 系列, EfficientNet-b6 模型在整个训练过程中一直保持最低的损失值。

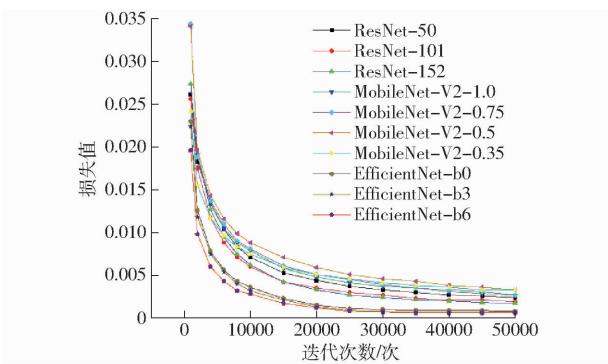


图 10 模型训练过程 Loss 曲线

Fig. 10 Loss curves of model training process

10 个主干网络模型的性能参数如表 1 所示, 从处理速度上比较, MobileNet-V2-0.75 模型检测速度最快, 达到 16.5 f/s, 但其在测试集误差较高, 更适合于时效性要求高于准确度要求的检测领域。EfficientNet-b0 模型内存占用量为 14.9 MB, 检测速度与均方根误差在 10 个模型中表现不错, 检测速度和准确度较为均衡。EfficientNet-b6 模型为 159.1 MB, 帧率为 3.8 f/s, 其在测试集上的误差最小, 适合用于高精度线测量, 需要更高的检测准确度, 因此选用 EfficientNet-b6 网络模型作为

DeepLabCut 算法的主干网络。

表 1 不同主干网络模型性能对比

Tab. 1 Performance comparison of different backbone network models

网络模型	模型内存 占用量/ MB	帧率/ (f·s <sup>-1</sup> )	训练集 误差/ 像素	测试集 误差/ 像素
ResNet-50	96.5	10.5	2.98	10.73
ResNet-101	172.6	9.4	3.06	23.25
ResNet-152	235.4	6.8	2.80	14.71
MobileNet-V2-1.0	10.4	14.2	5.49	13.26
MobileNet-V2-0.75	6.9	16.5	5.39	13.40
MobileNet-V2-0.5	4.2	15.6	6.01	12.16
MobileNet-V2-0.35	3.0	16.4	5.97	15.26
EfficientNet-b0	14.9	12.2	3.92	12.64
EfficientNet-b3	41.2	8.5	3.77	14.18
EfficientNet-b6	159.1	3.8	5.70	5.13

## 2.2 站立姿态分类模型分析

为了得到更为精确的站立姿态分类模型, 采用网格搜索法通过惩罚系数与 gamma 参数调节训练姿态检测模型。使用 288 组数据进行训练, 其中自然站立姿态 182 组, 非自然站立姿态 106 组。实验中将数据随机打乱, 80% 数据作为训练集, 20% 数据作为测试集。经测试与验证分析, 选用惩罚系数为 1, gamma 为 0.011 训练的自然站立姿态检测模型, 识别准确率为 94.82%。

## 2.3 离群特征点优化

为了验证本研究提出的离群特征点优化效果, 随机抽样一组带有离群特征点的图像进行误差分析, 其中点  $E_1, L_1, B$  在点云图中发生明显偏移。针对这 3 点, 利用 1.3.6 节所述的离群特征点的临近区域深度替换算法, 进行测试与分析。图 11 为离群特征点向外扩张距离  $d$  取不同值情况下, 特征点在点云图的分布情况。图 11a 为未针对离群特征点进行优化分布情况, 其中点  $E_1, B$  由于深度缺失, 记为 0, 将其转换成世界坐标系后, 该两点坐标均为  $(0, 0, 0)$ ; 点  $L_1$  在图像中轻微向猪体外侧偏移, 该点对应地面区域, 由于该点深度与实际点  $L_1$  深度差异明显, 导致转换后的世界坐标和实际位置相差较大。图 11b 为原始图像中离群特征点向外扩张成 21 像素  $\times$  21 像素区域( $d = 10$  像素), 优化后其特征点在点云图位置分布, 可以看出, 点  $E_1, L_1$  依然处于离群区域, 点  $B$  和真实尾根测量点无明显差异, 经计算该点与人工标记点的距离为 2.8 cm。图 11c 为原始图像中离群特征点向外扩张成 31 像素  $\times$  31 像素区域( $d = 15$  像素), 由优化后特征点在点云图位置分布情况可以看出,  $E_1, L_1$  分别与真实左耳尖、体宽左

测量点无明显差异,点B与真实尾根测量点有偏移,经计算该点与人工标记点的距离为8.1 cm。图11d为原始图像中离群特征点向外扩张41像素×41像素区域( $d=20$ 像素),由优化后其特征点在点云图位置分布情况可以看出, $E_l$ 、 $L_1$ 分别与真实左耳尖、体宽左测量点无明显差异,点B与真实尾根测量点存在明显偏移,经计算该点与人工标记点的距离为10.4 cm。

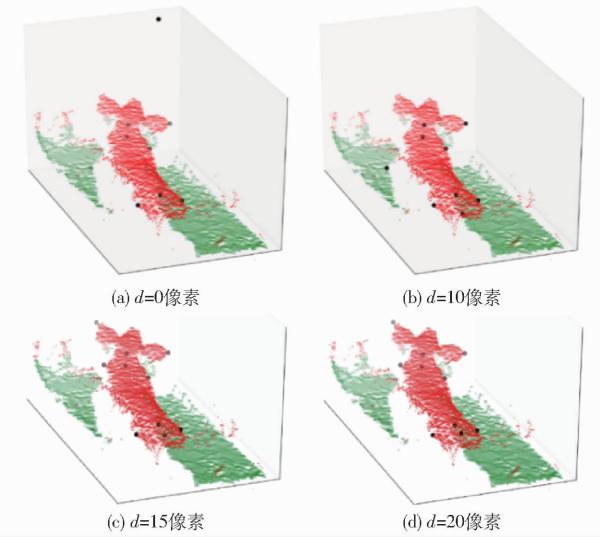


图11 不同扩张范围下离群特征点优化后的点云图

Fig. 11 Optimized point cloud images of outlier feature points under different expansion ranges

试验结果发现, $d$ 取不同值时,结果存在很大差异。 $d$ 过小,无法在扩张区域找到符合猪体深度范围的深度; $d$ 过大,造成优化后的位置与真实位置差异较大。为进一步优化离群特征点,采用 $d$ 值动态调节方法,从 $d=1$ 像素开始进行计算,对于每一个离群特征点,若扩张后矩形区域无法找到符合猪体深度范围的非零最小值,则 $d$ 值加1像素,直到找到符合猪体深度范围的深度数据为止,表2为手动标记点与动态调整后离群点结果对比表。手动标记特征点结果与动态调节离群特征点分布如图12所示。

表2 手动标记点与动态调整后离群点结果对比

Tab. 2 Comparison of results of manually marked points and outliers after dynamic adjustment

离群点	手动标记坐标	调整后坐标	距离
$E_l$	( -0.3792, 0.0226, -1.2360)	( -0.3984, 0.0292, -1.2480)	0.0236
B	(0.3665, 0.1852, -1.3230)	(0.3768, 0.1952, -1.3390)	0.0215
$L_1$	( -0.1678, 0.1048, -1.3310)	( -0.1769, 0.1239, -1.3490)	0.0278

本研究采取动态调节 $d$ 值方式对离群特征点进行测试,经过优化后离群特征点及骨架模型如图13所示。

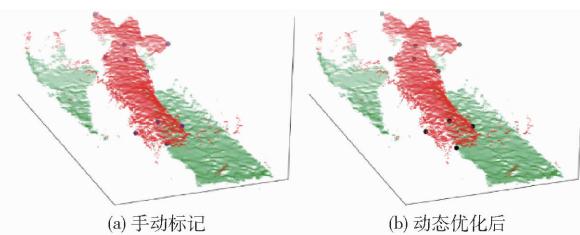


图12 手动标记特征点与动态调节离群特征点对比图

Fig. 12 Comparison between manually marked feature points and dynamically adjusted outlier feature points

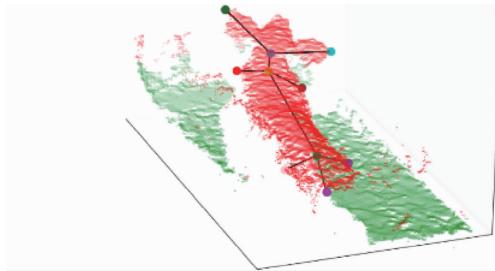


图13 猪只特征点与骨架3D图

Fig. 13 3D map of pig feature points and skeleton

## 2.4 体尺测量测试

为了验证本研究方法有效性,对日龄40~70 d长白猪进行现场测试,共采集140组RGB-D图像数据用于测试。部分体尺测量结果如图14所示,结果显示,在DeepLabCut关键点置信度设置为0.6时,基于DeepLabCut算法的特征点检测算法均可检测猪只背部图像的10个特征点。



图14 猪只体尺测量结果

Fig. 14 Pig body size measurement results

表3为部分猪只实际体尺与预测体尺数据及误差,经计算体长、体宽、体高、臀宽、臀高的均方根误差分别为1.79、1.07、0.72、1.25、1.46 cm;由计算结果可知均方根误差不大于1.79 cm,符合体尺测量误差要求。体宽、臀宽均方根误差不大于1.25 cm,但这两项参数基数较小,其误差与体长、体高及臀高相比误差略大。在上述试验环境下测试,体尺测量处理时间每帧为0.27 s,符合在线测量应用要求。

## 3 结论

(1)针对猪只体尺测量位置特征与数据集规模

表3 实际测量结果与算法计算结果对比

Tab. 3 Comparison between actual measurement results and algorithm calculation results

cm

猪只编号	体长		体宽		体高		臀宽		臀高	
	实际值	预测值								
001	60.10	59.20	19.30	17.90	41.20	40.90	17.80	18.90	43.50	43.10
002	64.10	62.30	15.00	16.50	42.00	42.60	18.00	18.90	41.00	40.10
003	54.90	52.90	16.70	16.00	39.60	37.60	17.20	18.60	40.40	40.00
004	59.30	58.80	16.90	18.00	41.70	41.60	18.30	20.20	37.80	37.80
005	63.10	64.90	17.90	19.50	43.20	43.20	20.60	20.10	40.10	40.00
006	62.00	63.90	18.60	19.70	44.30	44.00	18.00	17.00	41.40	42.80
007	66.00	66.10	19.10	20.40	45.40	45.60	17.40	17.40	43.10	41.70
008	64.10	67.00	19.30	19.30	40.90	40.70	20.10	22.00	43.70	42.10
009	53.30	54.10	18.90	18.60	38.10	38.10	18.50	18.30	37.10	38.50
010	51.80	54.60	18.70	19.00	36.20	36.90	15.50	17.30	36.90	37.40

程度,选取DeepLabCut算法进行10个主干网络模型训练与分析,经验证选用EfficientNet-b6网络模型作为猪只背部特征点提取的最优模型。

(2)使用离群特征点临近区域深度数据替换算法进行动态优化,有效解决了深度数据缺失与不合

理问题。

(3)通过现场真实环境测试,本文算法适用于部署在边缘计算单元实现猪只体尺实时精准测量的各项体尺参数,各项体尺数据均方根误差不大于1.79 cm,体尺测量处理时间每帧为0.27 s。

## 参 考 文 献

- [1] SKINNER L D, LEVESQUE C L, WEY D, et al. Impact of nursery feeding program on subsequent growth performance, carcass quality, meat quality, and physical and chemical body composition of growing-finishing pigs[J]. Journal of Animal Science, 2014, 92(3): 1044–1054.
- [2] HO K Y, TSAI Y J, KUO Y F. Automatic monitoring of lactation frequency of sows and movement quantification of newborn piglets in farrowing houses using convolutional neural networks[J]. Computers and Electronics in Agriculture, 2021, 189: 106376.
- [3] 谢秋菊,周红,包军,等.基于机器视觉的畜禽体质量评估研究进展[J].农业机械学报,2022,53(10):1–15.  
XIE Qiuju, ZHOU Hong, BAO Jun, et al. Review on machine vision-based weight assessment for livestock and poultry [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(10):1–15. (in Chinese)
- [4] 刘同海,滕光辉,张盛南,等.基于点云数据的猪体曲面三维重建与应用[J].农业机械学报,2014,45(6):291–295.  
LIU Tonghai, TENG Guanghui, ZHANG Shengnan, et al. Reconstruction and application of 3D pig body model based on point cloud data[J]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 45(6): 291–295. (in Chinese)
- [5] 徐宁迎,王先明,曹小英,等.长白猪主要选育性状间的典型相关分析[J].浙江大学学报(农业与生命科学版),2000,26(5):102–105.  
XU Ningying, WANG Xianming, CAO Xiaoying, et al. Canonical correlation analysis of main breeding traits for Landrace[J]. Journal of Zhejiang University(Agriculture and Life Sciences), 2000, 26(5): 102–105. (in Chinese)
- [6] CHENG Y Y, LIU S C, SU D, et al. Distribution and linkage disequilibrium analysis of polymorphisms of *GH1* gene in different populations of pigs associated with body size[J]. Journal of Genetics, 2016, 95(1): 79–87.
- [7] SCHOFIELD C P, MARCHANT J A, WHITE R P, et al. Monitoring pig growth using a prototype imaging system[J]. Journal of Agricultural Engineering Research, 1999, 72(3): 205–210.
- [8] FU W S, TENG G H, WANG Y Z. Web-based method for inspecting the pig body size and height using binocular stereovision technology[C]//Proceedings of the International Conference of Agricultural Engineering, 2008.
- [9] COMINOTTE A, FERNANDES A F A, DOREA J R R, et al. Automated computer vision system to predict body weight and average daily gain in beef cattle during growing and finishing phases[J]. Livestock Science, 2020, 232: 103904.
- [10] 尹令,蔡更元,田绪红,等.多视角深度相机的猪体三维点云重构及体尺测量[J].农业工程学报,2019,35(23):201–208.  
YIN Ling, CAI Gengyuan, TIAN Xuhong, et al. Three dimensional point cloud reconstruction and body size measurement of pigs based on multi-view depth camera[J]. Transactions of the CSAE, 2019, 35(23): 201–208. (in Chinese)
- [11] DESHAZER J A, MORAN P, ONYANGO C M, et al. Imaging systems to improve stockmanship in pig production[M]. UK: AFRC Institute of Engineering Research: Bedfordshire, 1988.
- [12] WHITE P, SCHOFIELD C P, GREEN D M, et al. The effectiveness of a visual image analysis (VIA) system for monitoring the performance of growing/finishing pigs[J]. Animal Science, 2004, 78(3):409–418.
- [13] DOESCHL-WILSON A B, WHITTEMORE C T, KNAPP P W, et al. Using visual image analysis to describe pig growth in terms of size and shape[J]. Animal Science, 2004, 79(3): 415–427.

- XUE Jinlin, LI Yuqing, CAO Zijian. Obstacle detection based on deep learning for blurred farmland images [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(3): 234–242. (in Chinese)
- [22] KUPYN O, MARTYNIUK T, WU J, et al. Deblurgan – v2: deblurring (orders-of-magnitude) faster and better [C] // Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 8878–8887.
- [23] KUPYN O, BUDZAN V, MYKHAILYCH M, et al. Deblurgan: blind motion deblurring using conditional adversarial networks [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8183–8192.
- [24] ZHAO Y, HAN R, RAO Y. A new feature pyramid network for object detection [C] // 2019 International Conference on Virtual Reality and Intelligent Systems (ICVRIS). IEEE, 2019: 428–431.
- [25] HORE A, ZIOU D. Image quality metrics: PSNR vs. SSIM [C] // 2010 20th International Conference on Pattern Recognition. IEEE, 2010: 2366–2369.
- [26] 沈跃, 庄珍珍, 刘慧, 等. 基于 RealSense 深度相机的多特征树干快速识别方法 [J]. 农业机械学报, 2022, 53(4): 304–312.
- SHEN Yue, ZHUANG Zhenzhen, LIU Hui, et al. Fast recognition method of multi-feature trunk based on RealSense depth camera [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(4): 304–312. (in Chinese)
- [27] ZHENG S, WU Y, JIANG S, et al. Deblur-YOLO: real-time object detection with efficient blind motion deblurring [C] // 2021 International Joint Conference on Neural Networks (IJCNN). IEEE, 2021: 1–8.
- 

(上接第 255 页)

- [14] 李卓, 杜晓冬, 毛涛涛, 等. 基于深度图像的猪体尺检测系统 [J]. 农业机械学报, 2016, 47(3): 311–318.
- LI Zhuo, DU Xiaodong, MAO Taotao, et al. Pig dimension detection system based on depth image [J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(3): 311–318. (in Chinese)
- [15] PEZZUOLO A, GUARINO M, SARTORI L, et al. On-barn pig weight estimation based on body measurements by a Kinect v1 depth camera [J]. Computers and Electronics in Agriculture, 2018, 148: 29–36.
- [16] 司永胜, 安露露, 刘刚, 等. 基于 Kinect 相机的猪体理想姿态检测与体尺测量 [J]. 农业机械学报, 2019, 50(1): 58–65.
- SI Yongsheng, AN Lulu, LIU Gang, et al. Ideal posture detection and body size measurement of pig based on Kinect [J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(1): 58–65. (in Chinese)
- [17] ZHANG J, ZHUANG Y, JI H, et al. Pig weight and body size estimation using a multiple output regression convolutional neural network: a fast and fully automatic method [J]. Sensors, 2021, 21(9): 3218.
- [18] TOSHEV A, SZEGEDY C. DeepPose: human pose estimation via deep neural networks [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014: 1653–1660.
- [19] INSAFUTDINOV E, PISHCHULIN L, ANDRES B, et al. DeeperCut: a deeper, stronger, and faster multi-person pose estimation model [C] // European Conference on Computer Vision, 2016: 34–50.
- [20] INSAFUTDINOV E, ANDRILUKA M, PISHCHULIN L, et al. ArtTrack: articulated multi-person tracking in the wild [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 6457–6465.
- [21] CAO Z, HIDALGO G, SIMOM T, et al. OpenPose: realtime multi-person 2D pose estimation using part affinity fields [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 43(1): 172–186.
- [22] 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.
- [23] BOVA A, KERNODLE K, MULLIGAN K, et al. Automated rat single-pellet reaching with 3-Dimensional reconstruction of paw and digit trajectories [J]. Journal of Visualized Experiments, 2019(149): e59979.
- [24] LABUGUEN R, BARDELOZA D K, NEGRETE S B, et al. Primate markerless poseestimation and movement analysis using DeepLabCut [C] // 2019 Joint 8th International Conference on Informatics, Electronics & Vision (ICIEV) and 2019 3rd International Conference on Imaging, Vision & Pattern Recognition (icIVPR). IEEE, 2019: 297–300.
- [25] NATH T, MATHIS A, CHEN A C, et al. Using DeepLabCut for 3D markerless pose estimation across species and behaviors [J]. Nature Protocols, 2019, 14(7): 2152–2176.
- [26] MATHIS A, BIASI T, SCHNEIDER S, et al. Pretraining boosts out-of-domain robustness for pose estimation [C] // Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision, 2021: 1859–1868.
- [27] WU Z, SHEN C, VAN DEN HENGEL A. Wider or deeper: revisiting the resnet model for visual recognition [J]. Pattern Recognition, 2019, 90: 119–133.
- [28] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770–778.
- [29] SANDLER M, HOWARD A, ZHU M, et al. MobileNetv2: inverted residuals and linear bottlenecks [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510–4520.
- [30] TAN M, LE Q. EfficientNet: rethinking model scaling for convolutional neural networks [C] // International Conference on Machine Learning, 2019: 6105–6114.