

doi:10.6041/j.issn.1000-1298.2020.S1.043

基于卷积神经网络的大白母猪发情行为识别方法研究

庄晏榕^{1,2} 余灵桦^{1,2} 滕光辉^{1,2} 曹孟冰^{1,2}

(1. 中国农业大学水利与土木工程学院, 北京 100083; 2. 农业农村部设施农业工程重点实验室, 北京 100083)

摘要: 针对现有发情检测方法灵敏度低、识别时间长、易受外界干扰等缺点,根据大白母猪试情时双耳竖立的特征,提出一种基于卷积神经网络(Convolutional neural network, CNN)的大白母猪发情行为识别方法。首先通过采集公猪试情时发情大白母猪与未发情大白母猪的耳部图像,划分训练集样本(80%)与验证集样本(20%)用于后期训练。随后,基于 AlexNet 卷积神经网络构建分类模型(AlexNet_Sow),并对该模型的网络结构进行简化,简化后的模型包含2个卷积模块和2个全连接模块,选择修正线性单元(Rectified linear units, ReLU)作为激活函数,用自适应矩估计(Adaptive moment estimation, Adam)方法优化梯度下降,选择 Softmax 作为网络分类器,通过结合增强学习的方法对模型进行训练,得到模型应用于验证集的准确率达到99%。此外,设定了发情鉴定的时间阈值,并结合 LabVIEW 的 Python 节点用于模型应用。当公猪试情时,大白母猪双耳竖立时长达到76 s时,则可判定其为发情。该方法对大白母猪发情识别的精确率、召回率与准确率分别为100%、83.33%、93.33%,平均单幅图像的检测时间为26.28 ms。该方法能够实现大白母猪发情的无接触自动快速检测,准确率高,大大降低了猪只应激情况和人工成本。

关键词: 母猪; 发情; 卷积神经网络; 深度学习; 双耳竖立

中图分类号: S828; TP391.4 文献标识码: A 文章编号: 1000-1298(2020)S1-0364-07

Recognition Method of Large White Sow Oestrus Behavior Based on Convolutional Neural Network

ZHUANG Yanrong^{1,2} YU Jionghua^{1,2} TENG Guanghui^{1,2} CAO Mengbing^{1,2}

(1. College of Water Resources and Civil Engineering, China Agricultural University, Beijing 100083, China

2. Key Laboratory of Agricultural Engineering in Structure and Environment, Ministry of Agriculture and Rural Affairs, Beijing 100083, China)

Abstract: Timely monitoring of sow oestrus is very important in sow breeding. Recently, recognition methods of sow oestrus are low sensitivity, wasting time and usually affected by environment. To resolve these problems, based on ear erect behavior of large white pigs during estrus, a method of large white sow's oestrus behavior recognition based on convolutional neural network (CNN) was proposed. A model based on AlexNet convolutional neural network, named AlexNet_Sow was firstly developed. Then, AlexNet_Sow model was simplified to get a new model named AlexNet_Sow_Simplified, which contained two convolution modules and two fully connected modules. The activation function of AlexNet_Sow_Simplified was rectified linear units (ReLU), adaptive moment estimation (Adam) was used to optimize gradient descent, and softmax was used to be the classifier of our model. Ear images of oestrus and non-oestrus large white sows were collected and divided into training data (80%) and testing data (20%). The model was trained by using data augmentation method, the accuracy of testing data was 99%. In addition, it was found that when sows' ears were erect for 76 s during teasing, it could be judged as the symbol of oestrus. In order to verify this method, LabVIEW Python nodes were used to intergrate the AlexNet_Sow_Simplified model and set a time threshold of 76 s and verified a set of new photos. The result showed that the precision rate, recall rate and accuracy rate of this method to recognize sow oestrus were 100%, 83.33%, and 93.33%, respectively. The average detecting time of a single image was

收稿日期: 2020-07-30 修回日期: 2020-09-20

基金项目: 国家重点研发计划项目(2016YFD0700204)

作者简介: 庄晏榕(1994—),男,博士生,主要从事设施养殖过程控制与环境研究, E-mail: zyr83691691@126.com

通信作者: 滕光辉(1963—),男,教授,博士生导师,主要从事农业生物环境智能控制和数字农业研究, E-mail: futong@cau.edu.cn

26.28 ms. It proved that this method could achieve non-contact, automatic, and fast detecting of oestrus in large white sows with high accuracy, which could greatly help to reduce sows' stress and the labor cost.

Key words: sow; oestrus; convolutional neural network; deep learning; ears erect

0 引言

生猪产业是我国重要的农业支柱产业之一^[1], 2019年,我国猪肉产量为4 255万t,占肉类总产量的55.63%^[2]。母猪在生猪产业中占有重要地位,其繁殖性能会影响猪场的生产效益^[3],为确保母猪有更好的繁殖性能,必须对猪只进行发情检测,发情检测的效率和准确性直接影响猪只的繁育性能和猪场的经济效益^[4]。

大白猪是著名的瘦肉型猪,繁殖性能好、瘦肉率高、生长速度快,常被选为母系中的父本或母本^[5]。大白母猪发情期间会出现一系列的表象,比如母猪的采食量降低,活动量增加^[6],母猪的阴户会出现红肿,并伴有粘液排出^[7],母猪会出现静立不动、双耳竖立等反应^[8]。工作人员可以通过母猪的异常表象对其发情进行推断,但这种方法对工作人员的经验水平要求较高,且无法进行量化,所以研究人员建立了许多自动化母猪发情检测技术和方法,如红外测温技术^[9-12],加速度计运动监测技术^[13-14],电子耳标监测^[15]等。但是,这些方法大多灵敏度较低,且监测周期较长,监测所需传感器多、技术复杂,不能实现快速、智能、便捷的母猪发情行为检测^[16]。

随着计算机技术的发展,许多学者利用机器视觉技术对猪只的行为进行了研究,并取得不错的效果^[17-20]。近年来,卷积神经网络(Convolutional neural network, CNN)被广泛应用于图像技术,如目标监测^[21]、细胞分裂^[22]、行为预测^[23]、视频分类^[24]、目标追踪^[25]及个体识别^[26]。这些研究为大白猪发情行为识别提供了丰富的经验。此外,CNN模型相比于传统机器视觉方法,易实现端对端操作,便于获得大白猪发情信息,为大白猪的发情行为识别提供了新的方向。

为使畜禽舍发情检测更智能化,减少工作人员主观判断带来的影响,本文建立基于CNN的快速、便捷、无应激的大白猪发情行为识别方法,采集大量大白母猪发情与未发情的耳部图像,通过深度学习对大白母猪双耳竖立的行为进行识别,并设定发情时双耳竖立时间阈值,以鉴定其是否发情。

1 材料与方法

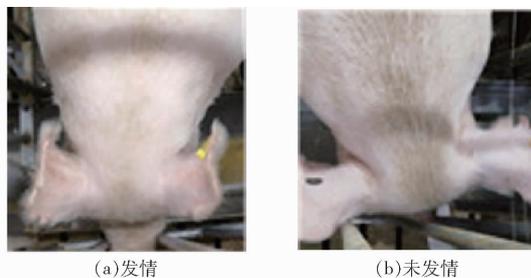
1.1 图像数据采集与分类

试验图像来自山东省滨州市无棣县荣昌育种有

限公司华辰母猪场,图像拍摄对象为限位栏饲养大白经产母猪。于猪舍过道内设置图像采集装置,每日对大白母猪于公猪试情时的耳部图像进行采集,猪只发情情况通过目测法观察。选用 Realsense D435 摄像头(美国谷歌公司),拍摄位置为猪只耳部正上方,使用可移动支架对摄像头进行移动,摄像头离地高度为1.1 m,与猪只耳部的距离约为0.5 m,拍摄频率为每秒一幅。试验共采集1 144幅未发情猪只的耳部图像,1 083幅发情猪只的耳部图像,每幅图像的尺寸为720像素×720像素,并手动按发情情况分类并标注标签。分别将两组数据按照4:1的比例分为训练集与验证集。

1.2 图像数据预处理

为了提高模型的准确性,减少过拟合现象的出现并增强模型泛化性,往往需要使用大量数据来进行训练^[27]。由于本试验周期短且图像样本较单一,容易使得神经网络出现过拟合^[28],过拟合现象会使模型的准确性下降^[29],因此需要在深度学习之前对图像数据进行预处理。首先将猪只耳部图像缩小至120像素×120像素,随后通过翻转、剪裁对图像数据集进行扩增。以图像的四角及中心位置为5个基准点,分别对一幅图像进行剪裁操作,得到5幅100像素×100像素的图像,之后对每幅图像分别进行水平及垂直翻转,可以得到20幅图像。每一幅初始图像都进行同样的操作。对数据增强后的图像进行筛选,发情猪只的耳部图像扩增至6 975幅,未发情猪只的耳部图像扩增至7 049幅。图1为经过数据处理的猪只发情与未发情时的耳部图像。



(a)发情 (b)未发情

图1 大白母猪耳部图像示例

Fig. 1 Examples of sows' ear images

1.3 卷积神经网络的构建

卷积神经网络是一种基于深度学习理论的神经网络^[30],主要由输入层、卷积层、池化层、全连接层及输出层构成^[31]。AlexNet是由KRIZHEVSKY等^[32]在2012年提出的一种卷积神经网络模型,

AlexNet 模型的准确率很高,在分类识别领域被广泛应用。因此,本试验选择在参考 AlexNet 模型框架的基础上,构建适合大白猪发情行为识别的卷积神经网络模型。

本文基于 AlexNet 网络结构,通过减少卷积层的层数及各层的卷积核尺寸与数量,设计了一个具有 7 层网络结构的深度卷积神经网络,命名为 AlexNet_Sow。该网络包含 4 个卷积模块和 3 个全连接模块,全连接模块采用 Softmax 作为激活函数。每个卷积模块都包含卷积层、最大池化层;全连接模块 fc1 和 fc2 包含卷积层,在训练时以一定的概率随机丢弃一部分神经元,其中本文设置丢弃的概率为 0.5。池化层对提取到的特征信息进行降维,简化了网络的计算复杂度,dropout 层的使用减少了神经元之间的依赖性,增强参数对数据集的泛化能力,减轻了过拟合现象^[33]。神经元的激活函数采用线性整流函数^[34] (Rectified linear unit, ReLU),该函数具有稀疏激活性,使模型不产生梯度弥散现象,有助于解决神经网络的收敛问题。

AlexNet_Sow 模型的各层具体参数如表 1 所示。

表 1 AlexNet_Sow 神经网络参数
Tab.1 Parameters of AlexNet_Sow

层类型	卷积核尺寸 与数量	步长	特征图尺寸与 神经元数量
输入层			100 × 100, 3
卷积层 C1	5 × 5, 32	1	100 × 100, 32
池化层 S1	2 × 2	2	50 × 50, 32
卷积层 C2	5 × 5, 64	1	50 × 50, 64
池化层 S2	2 × 2	2	25 × 25, 64
卷积层 C3	5 × 5, 128	1	25 × 25, 128
池化层 S3	2 × 2	2	12 × 12, 128
卷积层 C4	5 × 5, 128	1	12 × 12, 128
池化层 S4	2 × 2	2	6 × 6, 128
全连接层 fc1	1 × 1	1	1 024 维
全连接层 fc2	1 × 1	1	512 维
全连接层 fc3	1 × 1	1	2 维

各层的具体描述如下:

(1) 输入层。输入层的输入数据为经过预处理的大白母猪耳部图像,尺寸为 100 像素 × 100 像素。并将正副样本分别标记为“0”和“1”,分别代表双耳静立与未静立。

(2) 卷积层。卷积层的功能是提取输入的不同特征^[35]。卷积层输出的表达式如下

$$x_j^{(l)} = f\left(\sum_{i \in M_j} x_i^{(l-1)} * k_{ij}^{(l)} + b_j^{(l)}\right) \quad (1)$$

式中 l ——卷积层层数

$x_j^{(l)}$ ——第 l 层卷积层的第 j 个特征图

$x_i^{(l-1)}$ ——第 $l-1$ 层卷积层的第 i 个特征图

M_j ——输入特征图的子集

$k_{ij}^{(l)}$ ——第 l 层卷积层的第 j 个特征图与第 $l-1$ 层的第 i 个特征图之间相关的卷积核

$b_j^{(l)}$ ——第 l 层卷积层的第 j 个特征图对应的偏置系数

$f(\cdot)$ ——激活函数

本文网络构建采用的 4 个卷积层 C1、C2、C3、C4 均采用 5 × 5 的卷积核,卷积核个数分别为 32、64、128、128。

(3) 池化层。池化层可以有效地缩小参数矩阵的尺寸,使特征图拥有空间不变性,减少图像空间的大小^[36]。本文网络构建采用的 4 个池化层 S1、S2、S3、S4 均采用最大池化方法,即取出局部接受域中值最大的点,组成新的特征图,进而进行后续训练。最大池化的表达式^[30]如下

$$x_j^{(l+1)} = \beta_j \max(x_j^{(l)}) + b_j^{(l+1)} \quad (2)$$

式中 $x_j^{(l+1)}$ ——经过池化得到的特征图

β_j ——卷积层的权值系数

$b_j^{(l+1)}$ ——第 $l+1$ 层卷积层的第 j 个特征图对应的偏置系数

$\max(\cdot)$ ——最大池化函数

(4) 全连接层。全连接层的作用是将上一层得到的二维特征图转化为一维特征向量^[36],进而将其输入至分类器中,实现分类识别。本文网络构建采用的 3 个全连接层 fc1、fc2、fc3 的输出维数分别为 1 024、512、2。其中,fc1、fc2 层包含 dropout 层。fc3 层选用 Softmax 作为分类函数,计算大白猪行为类别的概率,进而得到识别结果,本文所用 Softmax 分类函数的分类数设定为 2。

1.4 模型优化

网络模型优化的实质是最小化损失函数^[37],应用优化算法,通过更新和计算影响模型训练和模型输出的网络参数,使其逼近或达到最优值,可实现最小化损失函数的目的^[38]。目前神经网络常用的优化算法包括随机梯度下降法 (Stochastic gradient descent, SGD)、Nesterov Momentum、RMSProp (Root mean square prop) 和 Adam (Adaptive moment estimation)^[39]。采用 AdamOptimizer 来实现模型优化,通过使用动量(参数的移动平均数)来改善传统梯度下降,促进超参数动态调整^[40]。Adam 算法相比于基础的 SGD 算法,具有不易陷入局部优点、速度更快等优势^[41]。参数更新表达式为

$$\theta_{t+1} = \theta_t - \frac{\alpha}{\sqrt{\hat{v}_t + \epsilon}} \hat{m}_t \quad (3)$$

其中
$$\hat{m}_t = \frac{m_t}{1 - \mu_1^t} \quad (4)$$

$$\hat{v}_t = \frac{v_t}{1 - \mu_2^t} \quad (5)$$

- 式中 t ——模型训练的时间步
 θ_t ——第 t 个时间参数数量
 θ_{t+1} ——经过参数更新后的第 $t+1$ 个时间步参数数量
 α ——学习率,取 0.001
 μ_1^t ——一阶矩估计的指数衰减率,取 0.9
 μ_2^t ——二阶矩估计的指数衰减率,取 0.999
 ε ——常数,避免除数变为 0,取 10^{-8}
 m_t ——一阶矩估计值
 v_t ——二阶矩估计值
 \hat{m}_t ——一阶矩估计的偏差修正值
 \hat{v}_t ——二阶矩估计的偏差修正值

1.5 模型简化

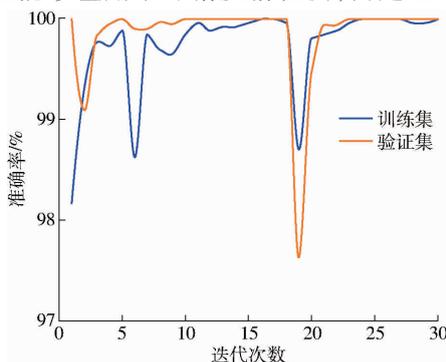
为提高模型的运算速度,本文从减少卷积层和池化层的角度对网络结构进行了简化,构建新的卷积神经网络模型,命名为 AlexNet_Sow_Simplified。简化后的模型包含 2 个卷积模块和 2 个全连接模块,与 AlexNet_Sow 模型相比,减少了 2 个卷积模块与 1 个全连接模块,模型的具体参数如表 2 所示。

表 2 AlexNet_Sow_Simplified 模型参数
 Tab.2 Parameters of AlexNet_Sow_Simplified

层类型	卷积核尺寸 与个数	步长	特征图尺寸与 神经元个数
输入层			100 × 100, 3
卷积层 C1	5 × 5, 32	1	100 × 100, 32
池化层 S1	2 × 2	2	50 × 50, 32
卷积层 C2	5 × 5, 64	1	50 × 50, 64
池化层 S2	2 × 2	2	25 × 25, 64
全连接层 fc1	1 × 1	1	1 024 维
全连接层 fc2	1 × 1	1	2 维

1.6 大白母猪发情判定阈值

为使得模型能够应用于母猪发情检测,需建立



阈值,获取最优检测时长,以提高发情检测的准确率与效率。每日公猪试情时,记录发情大白母猪双耳竖立时长,所得最长时长为 221 s,最短时长为 76 s,因此设定 76 s 为判定母猪发情与否的时间阈值。若模型检测出母猪双耳竖立且时长大于 76 s,则直接判定其发情;若模型检测出母猪双耳竖立但时长小于 76 s,则对猪只进行标记;若未检测出母猪双耳竖立,则直接判定其未发情。

2 结果与分析

2.1 试验测试平台

试验所用计算机 CPU 为 IntelCore i7 - 7700HQ 处理器,内存为 8 GB,显卡选用 NVIDIA GeForce GTX 1060,显存为 6 GB,并安装 Windows 10 系统(64 位)、Python3.5 编译环境、CUDA Toolkit 9.0、cuDNN V7.0 以及 Tensorflow - GPU 1.8.0 深度学习框架,采用 Python 语言进行编程。模型训练与验证均通过 GPU 进行加速。

2.2 模型评价指标

使用准确率(Accuracy)指标对模型分类效果进行定量评价^[42]。准确率的表达式为

$$P = \frac{T_p}{T_p + F_p} \times 100\% \quad (6)$$

- 式中 P ——准确率
 T_p ——分类正确的样本数
 F_p ——分类错误的样本数

2.3 模型训练与验证结果

神经网络训练参数设置为:每一个训练批次(Batch)的图像数量为 64,训练迭代次数(Epoch)为 30,初始学习速率为 0.001。图 2 为 AlexNet_Sow_Simplified 模型在训练集和验证集上的准确率及损失值随迭代次数变化曲线。从图 2a 中可知,模型在训练集与验证集上的准确率经 3 次迭代后快速上升至 99%,之后出现几次波动,但最终均稳定至 99% 以上。从图 2b 中可知,该模型在训练集和验证集上

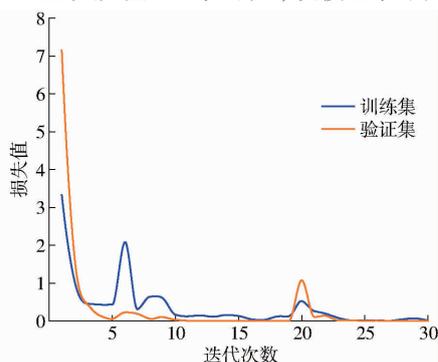


图 2 各模型准确率与损失值曲线

Fig.2 Accuracy and loss function curves of each model

的损失值随着迭代次数的增加不断下降,且最终趋近于0,模型不存在过拟合现象。

2.4 多类方法比较结果

为比较卷积神经网络训练完成的模型与其他方法训练所得模型的性能差异,本文选取了SVM、KNN与Adaboost 3种传统的图像分类方法,分别对模型进行了训练。并另外采集了300幅发情大白母猪的耳部图像与未发情大白母猪的耳部图像作为测试集,对比这4个模型在测试集上所消耗的测试时间(Testing time)、精确率(Precision)、召回率(Recall)与准确率(Accuracy)^[43]。各指标的计算公式如下

$$T = T_{\text{end}} - T_{\text{start}} \quad (7)$$

$$P_r = \frac{t_p}{t_p + f_p} \times 100\% \quad (8)$$

$$R_e = \frac{t_p}{t_p + f_n} \times 100\% \quad (9)$$

$$A_{cc} = \frac{t_p + t_n}{t_p + t_n + f_p + f_n} \times 100\% \quad (10)$$

式中 T ——测试时间 T_{start} ——起始时刻

T_{end} ——终止时刻 P_r ——精确率

R_e ——召回率 A_{cc} ——准确率

t_p ——将实际发情预测为发情的图像数

t_n ——将实际未发情预测为未发情的图像数

f_p ——将实际未发情预测为发情的图像数

f_n ——将实际发情预测为未发情的图像数

各模型的性能对比结果如表3所示。从表3中可知,KNN模型在测试集上的运算时间较长,且精确率与准确率最低,这是由于KNN在分类过程中需进行全局运算,计算复杂度、空间复杂度较高,对训练数据的依赖度也较大^[44];SVM方法训练所得模型在测试集上的运算时间最短,但精确率、召回率与准确率均较低,这是由于SVM利用核函数把多维数据向高维空间非线性映射,核函数的选择对最终的结果会产生影响^[45];Adaboost方法训练所得的模型在测试集上的表现较优于SVM与KNN;AlexNet_Sow_Simplified模型的测试准确率最高,测试时间也相对较低。

表3 不同模型试验结果对比

Tab.3 Comparison results of different methods

模型	测试 时间/s	精确率/ %	召回率/ %	准确率/ %
AlexNet_Sow_Simplified	15.77	98.02	99.00	98.50
SVM	6.89	76.92	76.67	76.83
KNN	22.87	71.60	84.00	75.33
Adaboost	9.39	80.18	87.66	83.00

在实际的查情过程中,一般更关注如何减少漏

查的发情母猪数目,提高查情的速度,增加查情的效率^[46]。因此,综合对比,AlexNet_Sow_Simplified模型是这4种模型中的最优模型。

2.5 自动发情检测实用性分析

判定阈值设定后,为进一步探究 AlexNet_Sow_Simplified模型的实用性,本文另选60头大白经产母猪进行模型性能检测,于猪场每日上午公猪试情时,采集母猪遇见公猪时的耳部图像。考虑到模型难以保证每帧图像的分类正确率,因此每头大白母猪的图像采集时间为90s,图像的采集频率为每秒一幅。并通过观察法确定其发情状况。若模型在采集的90幅图像内,所检测出的发情图像超过76幅,则判定该母猪发情;若模型检测出的发情图幅少于76幅且大于1幅,则判定该母猪的发情状况为待定;若模型未检测出发情图像,则判定该母猪未发情。现场共有24头母猪处于发情期,其中20头母猪的阴户红肿且表现出静立反应,即发情显著;4头母猪的阴户红肿但未表现出静立反应,即发情不显著;36头母猪处于未发情时期。

为将 Alexnet_Sow_Simplified模型与发情判断阈值相结合,实现发情检测的自动化,本文利用 LabVIEW2018(64位)中的 Python节点对建立好的模型进行调用,并设定时间判定条件,通过连续读取所拍摄的一组图像,对猪只发情进行判定,使系统更简单化、集成化。随后对所获取图像进行实测,系统判定发情母猪数为19,待定母猪数为1,未发情母猪数为40,且未出现将未发情母猪判定为发情的情况,可得本文方法的发情检测精确率为100%,召回率为83.33%,准确率为93.33%,对单幅图像的检测时长为26.28ms。本文方法召回率与红外行为传感器^[47](79%)、加速度传感器^[14](53%)在性能上具有优势,且检测耗时较短。

3 结束语

针对母猪发情检测自动化的需求,根据大白母猪发情时的双耳竖立行为,提出了一种基于卷积神经网络的大白母猪发情行为识别方法。基于 AlexNet 卷积神经网络,建立卷积神经网络模型 AlexNet_Sow,并对其进行了简化,建立了 AlexNet_Sow_Simplified模型,通过对发情与未发情的母猪耳部图像进行训练,该模型的验证集准确率达到99%,该模型相较于传统图像分类模型,性能更优。通过公猪试情时双耳竖立对母猪发情进行判断,在获得良好模型的前提下,还需要设定时间阈值。通过 LabVIEW 对 AlexNet_Sow_Simplified模型进行调用,并在程序内设定时间阈值对模型进行实用性分析,对60头大白经产母猪进行发情判定,识别精确

率为 100%, 召回率为 83.33%, 准确率为 93.33%, 单幅图像检测时长为 26.28 ms。试验结果表明, 该方法识别率高, 能够较好地对猪只发情进行检测, 且相比基于红外传感器、加速度传感器的发情检测, 准

确率有明显提升, 且检测耗时较短, 可以较好地实现大白母猪发情行为的智能化、简易化检测, 大大降低了母猪应激情况和人工成本, 可为我国生猪智能养殖提供技术支撑。

参 考 文 献

- [1] 印遇龙. 准确把握新常态下的生猪产业发展趋势[J]. 中国畜牧业, 2015(15): 83.
- [2] 国家统计局. 2019 年国民经济和社会发展统计公报[R/OL]. (2020-02-28). <http://data.stats.gov.cn/easyquery.htm?cn=C01>.
- [3] 陈志明, 陈芳杰. 能繁母猪优质管理建议[J]. 中国畜牧兽医文摘, 2015, 31(10): 66.
- [4] 韩志强, 王海军, 赵家平, 等. 动物发情鉴定技术的研究进展[J]. 畜牧兽医学报, 2018, 49(10): 2086-2091.
HAN Zhiqiang, WANG Haijun, ZHAO Jiaping, et al. Research progress of estrus identification technology in animals[J]. Acta Veterinaria et Zootechnica Sinica, 2018, 49(10): 2086-2091. (in Chinese)
- [5] 孟庆利, 王丽丽, 周海深, 等. 法系大白种猪肥育后期生长发育规律的研究[J]. 养猪, 2014(2): 47-48.
- [6] 郎介金, 杨培新, 缪永兴, 等. 长白母猪发情行为特征系统观察[J]. 黑龙江动物繁殖, 1997(2): 12-13.
- [7] 梁作生, 薛强. 种母猪的人工繁殖技术[J]. 黑龙江动物繁殖, 2016, 24(4): 16-17.
- [8] 马称发. 断奶母猪排卵时间的相关研究[D]. 广东: 华南农业大学, 2016.
MA Chengfa. The research of ovulating time in weaned sows[D]. Guangdong: South China Agricultural University, 2016. (in Chinese)
- [9] 秦永孝, 王玉梁, 高雪峰, 等. 基于红外设备的母猪发情状态下体温变化研究[J]. 畜牧兽医学报, 2016, 47(1): 85-91.
QIN Yongxiao, WANG Yuliang, GAO Xuefeng, et al. Temperature changes during estrus in swine was studied by infrared temperature measurement device[J]. Acta Veterinaria et Zootechnica Sinica, 2016, 47(1): 85-91. (in Chinese)
- [10] SCOLARI S C, CLARK S G, KNOX R V. Vulvar skin temperature changes significantly during estrus in swine as determined by digital infrared thermography[J]. Journal of Swine Health & Production, 2011, 19(3): 151-155.
- [11] SYKES D J, COUVILLION J S, CROMIAK A, et al. The use of digital infrared thermal imaging to detect estrus in gilts[J]. Theriogenology, 2012, 78(1): 147-152.
- [12] SIMÕES V G, LYAZRHI F, PICARD H N, et al. Variations in the vulvar temperature of sows during proestrus and estrus as determined by infrared thermography and its relation to ovulation[J]. Theriogenology, 2014, 82(8): 1080-1085.
- [13] BRESSERS H P M. Monitoring individual sows in group-housing: possibilities for automation[D]. Wageningen: Wageningen University & Research, 1993.
- [14] SERLET S. Optimalisatie van bronstdetectie bij zeugen[D]. Copenhagen: University of Copenhagen, 2004.
- [15] KORTHALS R L. The effectiveness of using electronic identification for the identification of estrus in swine[C]// ASAE/CSAE-SCGR Annual International Meeting, ASAE, 1999: 10.
- [16] 余灵桦. 基于气味和声音的母猪试情平台研究[D]. 北京: 中国农业大学, 2019.
YU Jionghua. Research on automatic oestrus detection system of sows based on smells and sounds[D]. Beijing: China Agricultural University, 2019. (in Chinese)
- [17] SHAO J, XIN H, HARMON J. Neural network analysis of postural behavior of young swine to determine the air thermal comfort state[J]. Transactions of the ASAE, 1997, 40(3): 755-760.
- [18] KASHIHA M, BAHR C, HAREDAŠT S A, et al. The automatic monitoring of pigs water use by cameras[J]. Computers and Electronics in Agriculture, 2013, 90(90): 164-169.
- [19] 谢徽, 田建艳, 王芳, 等. 基于几何参数特征与决策树支持向量机的猪只姿态分类[J]. 黑龙江畜牧兽医, 2015(19): 21-25.
- [20] 郭依正. 基于机器视觉的俯视群养猪个体识别与饮水行为分析研究[D]. 镇江: 江苏大学, 2018.
GUO Yizheng. Study on individual recognition and drinking behavior analysis of top view group-housed pigs based on machine vision[D]. Zhenjiang: Jiangsu University, 2018. (in Chinese)
- [21] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//27th IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2014: 580-587.
- [22] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39(4): 640-651.
- [23] TOSHEV A, SZEGEDY C. DeepPose: human pose estimation via deep neural networks[C]//27th IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2014: 1653-1660.
- [24] KARPATHY A, TODERICI G, SHETTY S, et al. Large scale video classification with convolutional neural networks[C]//27th IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2014: 1725-1732.
- [25] WANG N, YEUNG D. Learning a deep compact image representation for visual tracking[C]// In Advances in Neural Information Processing Systems. Curran Associates Inc., 2013: 809-817.
- [26] HANSEN M, SMITH M, SMITH L, et al. Towards on-farm pig face recognition using convolutional neural networks[J].

- Computers in Industry, 2018, 98: 145 – 152.
- [27] 刘万军, 梁雪剑, 曲海成. 基于双重优化的卷积神经网络图像识别算法[J]. 模式识别与人工智能, 2016, 29(9): 856 – 864.
LIU Wanjun, LIANG Xuejian, QU Haicheng. Convolutional neural network algorithm based on double optimization for image recognition[J]. Pattern Recognition and Artificial Intelligence, 2016, 29(9): 856 – 864. (in Chinese)
- [28] PARAG S C, LI B X. Capturing localized image artifacts through a CNN-based hyper-image representation[J]. arXiv preprint arXiv, 2017: 1711.04945.
- [29] HAO S, QI C R, LI Y Y, et al. Render for CNN: viewpoint estimation in images using CNNs trained with rendered 3D model views[C]//IEEE International Conference on Computer Vision. IEEE, 2015: 2686 – 2694.
- [30] 刘忠超, 何东健. 基于卷积神经网络的奶牛发情行为识别方法[J/OL]. 农业机械学报, 2019, 50(7): 186 – 193.
LIU Zhongchao, HE Dongjian. Recognition method of cow estrus behavior based on convolutional neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(7): 186 – 193. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20190719&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2019.07.019. (in Chinese)
- [31] TOLIAS G, SICRE R, JÉGOU H. Particular object retrieval with integral max-pooling of CNN activations [C]//4th International Conference on Learning Representations. ICLR, 2016: 1 – 12.
- [32] KRIZHEVSKY A, SUTSKEVER I, HINTON G. Imagenet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84 – 90.
- [33] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting [J]. Journal of Machine Learning Research, 2014, 15(1): 1929 – 1958.
- [34] HESAMIFARD E, TAKABI H, GHASEMI M. CryptoDL: deep neural networks over encrypted data [C]//5th International Conference on Learning Representations. ICLR, 2017: 1 – 21.
- [35] RAZAVIAN A S, AZIZPOUR H, SULLIVAN J, et al. CNN features off-the-shelf: an astounding baseline for recognition [C]//27th IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2014: 512 – 519.
- [36] 朱金朵. 基于深度学习的新生儿疼痛表情识别[D]. 南京:南京邮电大学, 2018.
ZHU Jinduo. Neonatal pain expression recognition based on deep learning[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2018. (in Chinese)
- [37] DANIEL J I, MICHAEL T, KRISTIN B. An empirical analysis of the optimization of deep network loss surfaces[J]. arXiv preprint arXiv, 2016: 1612.04010.
- [38] 刘晶, 和述群, 朱清香, 等. 基于深度学习的线上农产品销量预测模型研究[J]. 计算机应用研究, 2017, 34(8): 2291 – 2293.
LIU Jing, HE Shuqun, ZHU Qingxiang, et al. Online agricultural product sales prediction model research based on deep learning[J]. Application Research of Computers, 2017, 34(8): 2291 – 2293. (in Chinese)
- [39] 王功鹏, 段萌, 牛常勇. 基于卷积神经网络的随机梯度下降算法[J]. 计算机工程与设计, 2018, 39(2): 441 – 445, 462.
WANG Gongpeng, DUAN Meng, NIU Changyong. Stochastic gradient descent algorithm based on convolution neural network [J]. Computer Engineering and Design, 2018, 39(2): 441 – 445, 462. (in Chinese)
- [40] KESKAR N S, SOCHER R. Improving generalization performance by switching from adam to SGD [C]//5th International Conference on Learning Representations. ICLR, 2017: 15 – 25.
- [41] KINGMA D P, BA J. Adam: a method for stochastic optimization [C]//3th International Conference on Learning Representations. ICLR, 2015: 1 – 15.
- [42] 赵志衡, 宋欢, 朱江波, 等. 基于卷积神经网络的花生籽粒完整性识别算法及应用[J]. 农业工程学报, 2018, 34(21): 195 – 201.
ZHAO Zhiheng, SONG Huan, ZHU Jiangbo, et al. Identification algorithm and application of peanut kernel integrity based on convolution neural network[J]. Transactions of the CSAE, 2018, 34(21): 195 – 201. (in Chinese)
- [43] RENÉ B, AGUSTÍN C C, RANA O F, et al. Network-aware summarisation for resource discovery in P2P-content networks [J]. Future Generation Computer Systems, 2012, 28(3): 563 – 572.
- [44] HWANG W J, WEN K W. Fast KNN classification algorithm based on partial distance search[J]. Electronics Letters, 1998, 34(21): 2062 – 2063.
- [45] HSU C W, LIN C J. A comparison of methods for multiclass support vector machines[J]. IEEE Transactions on Neural Networks, 2002, 13(2): 415 – 425.
- [46] 方礼禄, 沈君, 严彩虹, 等. 定时输精对断奶母猪繁殖性能的影响[J]. 饲料博览, 2017, 38(16): 49 – 52.
FANG Lili, SHEN Jun, YAN Caihong, et al. The effect of timing of insemination on the reproductive performance of weaned sows[J]. Feed Review, 2017, 38(16): 49 – 52. (in Chinese)
- [47] FRESON L, GODRIE S, BOS N, et al. Validation of an infra-red sensor for oestrus detection of individually housed sows[J]. Computers and Electronics in Agriculture, 1998, 20(1): 21 – 29.