

基于红外热成像的白羽肉鸡体温检测方法

沈明霞¹ 陆鹏宇¹ 刘龙申¹ 孙玉文¹ 许毅² 秦伏亮¹

(1. 南京农业大学工学院, 南京 210031; 2. 新希望六和股份有限公司, 青岛 266100)

摘要: 为了快速、准确地检测肉鸡体温,提出了一种红外热成像技术和深度学习相结合的肉鸡体温检测方法。以卷积神经网络为基础,建立肉鸡头部和腿部的感兴趣区域(Region of interest, ROI)识别模型,提取肉鸡头部和腿部的最高温度,结合环境温度、相对湿度和光照强度,分别构建了基于多元线性回归和基于BP神经网络的肉鸡翅下体温反演模型。试验结果表明,基于深度卷积神经网络(Convolutional neural networks, CNNs)的感兴趣区域识别模型在测试集上的查准率和查全率分别为96.77%和100%,基于多元线性回归和BP(Back propagation)神经网络的反演模型平均相对误差分别为0.33%和0.29%。基于BP神经网络的肉鸡翅下温度反演模型具有更高的准确性,可准确检测肉鸡体温。

关键词: 肉鸡; 体温; 热红外成像; 卷积神经网络; 多元线性回归; BP神经网络

中图分类号: S831.4 **文献标识码:** A **文章编号:** 1000-1298(2019)10-0222-08

Body Temperature Detection Method of Ross Broiler Based on Infrared Thermography

SHEN Mingxia¹ LU Pengyu¹ LIU Longshen¹ SUN Yuwen¹ XU Yi² QIN Fuliang¹

(1. College of Engineering, Nanjing Agricultural University, Nanjing 210031, China

2. New Hope Liuhe Co., Ltd., Qingdao 266100, China)

Abstract: In broiler production, the temperature under the wing is an important indicator of animal health and welfare condition. Body temperature detection method of broiler based on infrared thermography was proposed to achieve measurement of broiler body temperature accurately and rapidly. The detected region of interest (ROI) model of broiler head and leg, based on a convolutional neural network, was developed to extract the maximum temperature of its head and leg. Besides, combined with ambient temperature, humidity and light intensity, two different broiler wing temperature inversion models were proposed by multiple linear regression and back propagation (BP) neural networks, respectively. And the experimental results showed that, based on the deep convolutional neural network, the ROI detected model achieved a precision and recall rate of 96.77% and 100% on the test dataset, respectively. What's more, the temperature inversion models achieved an average relative error of 0.33% with multiple linear regression, while BP neural network was 0.29%. Deep learning method was used to obtain the ROI temperature, which was superior to the image processing method, high in efficiency and high in generalization ability. BP neural network model error was less than the error of multiple linear regression network model. Therefore, BP neural network can be applied as a temperature inversion model of broiler wings. BP neural network had the ability of self-learning and self-adaptation, and its generalization ability was strong. Applying it to the inversion of temperature under the wing can improve the accuracy and adaptability of the model. This model provided reliable technical support for real-time monitoring of broiler body temperature.

Key words: broiler; body temperature; infrared thermography; convolutional neural network; multiple linear regression; BP neural network

收稿日期: 2019-07-24 修回日期: 2019-08-19

基金项目: 政府间国际科技创新合作重点专项(2017YFE0114400)

作者简介: 沈明霞(1964—),女,教授,博士生导师,主要从事机器视觉与信息农业研究,E-mail: mingxia@njau.edu.cn

0 引言

畜禽个体信息的智能感知与分析是畜禽精准健康养殖的关键^[1]。体温是畜禽个体信息的重要指标^[2-3],快速、准确地获取畜禽体温是畜禽养殖行业的迫切需求,也是目前该领域的研究热点。传统畜禽体温检测主要依靠耗时、费力且主观性强的人工检测方法^[4]。近年来,红外热成像检测技术因其具有无应激、无损伤的优势,而替代了人工检测,并逐步被应用于畜禽的体温与生理疾病检测之中^[5]。

在大型牲畜体温检测技术研究中,目前通常采用红外热成像技术和图像处理方法提取 ROI 温度,以反映大型牲畜疾病与生理特征^[6-12]。而在将红外热成像技术应用于小个体的鸡只体温、疾病与生理特征检测时^[13-17],由于身体被羽毛覆盖,特征区域不明显,且更易受应激影响,因此存在技术瓶颈。对蛋鸡的体温检测研究中,杨威^[18]将传感器分别穿戴在鸡的腿部、胸部以及泄殖腔 3 个部位,数据显示,鸡胸部位的温度处于 39.5 ~ 41.2℃ 之间,是温度最为平稳的部位,具有一定的指标意义。但接触式测温的方法易造成鸡只应激反应,且装置容易被鸡只啄击而导致脱落、失灵,适应性较低,也不符合鸡只的福利养殖要求。陆辉山等^[19]采用红外热像仪研究了蛋鸡相关体表区域温度与翅下温度的关系,选取适当的点作为 ROI 温度,使用电子体温计获取翅下温度,采用多元线性拟合方法建立翅下温度与头部、腿部温度的关系模型,该模型预测结果的平均误差为 0.05℃,最大误差为 0.21℃。与蛋鸡相比,白羽肉鸡生长速度快,而羽毛生长缓慢且覆盖不均匀,体表裸露部分较多,极易干扰 ROI 温度提取。目前,未见采用红外热成像技术检测肉鸡体温的相关研究报道。

为此,本研究提出一种红外热成像技术和深度学习相结合、定性与定量检测肉鸡体温的方法。首先基于深层卷积神经网络提取 ROI 温度,然后采用多元线性回归以及 BP 神经网络两种方法建立肉鸡翅下温度反演模型,以期为肉鸡疾病诊断和健康养殖提供技术支撑。

1 材料和方法

1.1 试验对象

试验于 2019 年 1 月与 3 月在山东省青岛市新希望六和股份有限公司进行,从鸡舍内 21 000 多只白羽肉鸡中随机挑选 30 只鸡龄为 35 d、平均质量为 2 kg 的白羽肉鸡作为试验对象。

1.2 试验仪器

Hair ST - 800 型无线电子体温计,测量范围 25 ~ 45℃,测量精度 ± 0.1℃。272 - A 型温湿度计,温度测量范围 - 10 ~ 50℃,测量精度 ± 1℃,相对湿度测量范围 0 ~ 100%,测量精度 ± 5%。ZD - 802 型光照度计,测量范围 0.1 ~ 200 000 lx,测量精度 ± 5%。FLIR TAU2640 型红外热像仪,测量范围 - 40 ~ 80℃,测量精度 ± 2℃,图像分辨率 640 像素 × 512 像素,像素间距 17 μm,成像时间小于 0.5 s。

1.3 数据采集

鸡舍的环境温度在 19.8 ~ 23.7℃ 范围内,环境相对湿度在 13% ~ 79% 范围内。舍内光照强度白天稳定在 3.5 lx 左右,20:00—23:00 舍内熄灯,光照强度为 0 lx。

选取环境温度较为平稳的区域作为拍摄背景,将无线电子体温计固定在鸡只翅下,然后放置在拍摄区域内,将红外热像仪放置距鸡只侧身 1.2 m 处。等待至鸡只平稳无应激,连续拍摄 5 幅鸡只侧身热红外图像,并记录环境温湿度及光照强度。图 1 为体温采集示意图。




图 1 体温采集示意图

Fig. 1 Sketch of body temperature collection

1. 无线电子体温计 2. 温湿度计 3. 光照度计 4. 红外热像仪

2 感兴趣区域温度提取

2.1 感兴趣区域选取

在红外热像仪所拍摄的图像中,如图 2 所示,具有显著温度差异的鸡只前景区域与周围背景区域呈现出两种不同趋势的颜色。在图像的鸡只区域里,鸡只头部与腿部温度较高,与身体其他部分有较为明显的颜色差异。且由于没有羽毛覆盖,腿部与头部可以直接接触环境^[19]。所以取头部与腿部作为试验的特征区域即为 ROI,并取头部与腿部最高温度作为感兴趣区域温度^[20]。

2.2 感兴趣区域识别模型设计

在热红外图像中会存在尾部、胸脯等羽毛未覆盖区域和鸡粪等高温干扰因素。对一整幅图像进行处理和温度数据提取,将会增加数据处理时间,降低效率。因此,本试验采用深层卷积神经网络识别 ROI,并提取 ROI 温度数据。




图2 白羽肉鸡热红外图

Fig.2 Thermal infrared image of white feather broiler
1.头部 2.腿部 3.尾部 4.胸脯 5.鸡粪

卷积神经网络由卷积层、池化层、全连接层和输出层构成。卷积层内部包含多个卷积核,对输入图像数据进行特征提取。池化层包含预设的池化函数,通过降低特征图的空间尺寸,进行二次特征提取。全连接层搭建在隐含层最后,可以整合卷积层或池化层中具有类别区分性的局部信息^[21-22]。

本文采用的是类 YOLOv3 网络模型,该模型的主体结构是 Darknet53,将分类和定位合并为一个任务进行目标识别^[23-24],其工作流程如图 3 所示。




图3 类 YOLOv3 网络模型的工作流程图

Fig.3 Workflow chart of YOLOv3 network model
将归一化后的图像数据放进输入层,网络对图

像进行 3 次倍降采样,提取输出层特征,并在特征交互层中将两次上采样的特征与输出特征通过特征金字塔网络(FPN)算法融合,得到 3 种尺寸的目标预测,最终输出层输出识别结果。

模型卷积层大量融合图 4 所示的残差结构,可在反向传播过程中解决梯度消失问题并控制过拟合。每个残差结构块包含 2 个卷积层,卷积核尺寸分别为 1×1 和 3×3 。每一层卷积层后都进行批量特征归一化操作,并通过激活函数进行非线性处理,激活函数为 LeakyReLU 函数。




图4 残差结构图

Fig.4 Residual block

图 5 是该模型的结构图。通过 FPN 算法,将 97 层上采样特征与 36 层输出特征拼接融合得到大尺寸目标的特征图;将 85 层上采样特征与 61 层输出特征拼接融合得到中尺寸目标的特征图;将 79 层输出的特征取出,得到小尺寸目标的特征图。3 种尺寸的特征图聚类出 9 种尺寸的先验框,9 种先验框可以实现对大、中、小 3 种尺寸目标的检测。




图5 模型结构图

Fig.5 Diagram chart of model structure

2.3 感兴趣区域识别模型训练

2.3.1 训练样本来源

试验期间每天进行 4 次数据采集,时间分别为 09:00—10:30、13:00—14:30、16:00—17:30 和 20:00—21:30。连续采集 7 d,试验期间共采集 940 组数据,剔除无效数据后共计 900 组数据。使用开源图像标注软件 Labellmg 进行图像标注,标注图像包括 3 通道图像 900 幅,标注格式为 PASCAL VOC 数据集标准格式,每幅图像标注后会对应生成 xml 标签。

2.3.2 训练平台与训练参数设计

训练平台为 1 台酷睿 i9-9900kCPU 工作站,配有 RTX2080Ti,显存为 11 GB,32 GB 内存。

将试验采集的 900 幅图像按照 8:1:1 分为训练集、验证集和测试集;初次训练迭代 30 000 次,再次训练迭代 10 000 次;采用 Batch 值为 64 的 Mini-batch 随机梯度下降法训练;学习策略为步进型,学习率初始化为 0.001,冲量 0.9,衰减因子为 0.000 5;为 13 像素×13 像素、26 像素×26 像素和 52 像素×52 像素 3 种尺寸的预测图像各分配 3 个先验框。

2.3.3 模型评价

采用查准率 P (Precision) 和查全率 R_e (Recall) 对识别结果进行评价,计算公式如下

$$P = \frac{T_p}{T_p + F_p} \times 100\%$$

$$R_e = \frac{T_p}{P_s} \times 100\%$$

式中 T_p ——真正样本 F_p ——假正样本
 P_s ——正样本,包括真正样本和假负样本

经过 YOLOv3 深层卷积神经网络训练得到目标检测模型,测试集中的图像检测结果如图 6 所示。模型在测试数据集的 90 幅图像上实测得到查准率和查全率分别为 96.77% 和 100%。对检测结果进行可视化分析,图像在训练集、验证集、测试集中分布方式相同、热红外图像采集的场景简单且无环境干扰、肉鸡的头部和腿部特征较为明显,模型可以对肉鸡的头部和腿部进行无偏差识别,检测结果出现少量假正样本,将肉鸡翅下裸露严重区域识别成头部,这主要是由模型出现轻微过拟合导致,可通过数据增强方法进行修正。

2.4 输出感兴趣区域温度

通过对输出结果的调整,使输出结果为预测框的左上角和右下角的坐标。头部左上角坐标为(76,52),头部右下角坐标为(178,126),腿部左上角坐标为(230,263),腿部右下角坐标为(433,441)。

红外热像仪拍摄的图像尺寸为 640 像素×512 像




图 6 鸡只头部与腿部识别结果

Fig. 6 Chicken head and leg recognition results

素,热红外图像的每个像素点在相应的 CSV 文件里对应一个温度数据,即一幅热红外图像有 640×512 个温度数据,这些数据用逗号间隔,通过提取像素点的纵横坐标,在 CSV 文件里提取相应的温度数据。

通过识别两个 ROI 的左上顶点坐标和右下顶点坐标,得到 ROI 的所有像素点坐标。在相应的 CSV 文件里,根据坐标得到 2 个目标区域的温度最大值,头部温度最大值为 40.4℃,腿部温度最大值为 39.7℃。

一组数据中包含 5 幅热红外图像,提取每组数据中 5 组 ROI 温度,取其平均值作为最终 ROI 温度。

3 白羽肉鸡翅下温度分析

本试验共采集 6 类试验数据:翅下温度、头部最大温度、腿部最大温度、环境温度、环境相对湿度、光照强度。表 1 是应用上述测温方法得到 6 类试验数据的部分结果。在实际鸡场环境中,由于风机及窗户的开关,对环境有一定程度上的影响。由表 1 可以得出,受环境因子的影响,鸡只的平均体温为 39.8℃。

表 1 部分试验数据
Tab.1 Partial test data

编号	翅下温度/℃	头部温度/℃	腿部温度/℃	环境温度/℃	相对湿度/%	光照强度/lx
1	39.6	39.00	40.3	20.0	74	3.6
2	39.3	39.10	39.4	20.0	74	3.6
3	39.4	39.80	40.6	20.0	74	3.6
4	39.7	38.94	40.2	22.1	36	3.5
5	39.8	38.94	39.4	22.1	36	3.5
6	39.8	39.60	39.9	22.2	37	3.7
7	39.6	39.20	39.3	22.2	37	3.7
8	39.6	38.60	39.4	22.2	37	3.7
9	39.7	39.60	40.5	20.0	43	0
10	39.6	39.30	40.7	20.0	43	0
11	40.0	41.10	41.5	22.2	17	0
12	40.2	39.80	41.0	22.2	17	0
13	40.0	40.40	38.6	22.0	14	0
14	40.1	40.70	41.8	22.0	14	0
15	40.1	40.40	40.6	22.0	14	0

考虑肉鸡自身及外界多种变量因素对肉鸡翅下温度产生影响,因此,本试验以翅下温度为反演目标,建立体温反演模型。

通常建模方法包括多元线性回归和基于神经网络的多元回归分析。其中多元线性回归是一种线性建模方法,而基于神经网络的多元回归是一种非参数、非线性方法。本文采用这两种方法建立反演模型,并对比模型结果。

3.1 多元线性回归反演模型

本试验采用 SPSS 软件对肉鸡翅下温度进行多元线性回归分析。从 900 组数据中选取 850 组数据作为训练集,50 组数据作为测试集。将数据录入 SPSS 软件,进行多元线性回归分析,其模型结果如表 2 所示。

表 2 6 种模型信息汇总

Tab.2 Summary of six kinds of model information					
模型	R	R ²	标准估计误差	F	p
1	0.212	0.045	0.256	11.992	0.001
2	0.842	0.708	0.144	307.075	0
3	0.850	0.723	0.140	218.851	0
4	0.857	0.735	0.137	174.028	0
5	0.864	0.747	0.134	185.477	0
6	0.865	0.747	0.134	147.911	0

表 2 中 6 种模型的 p 值均小于 0.01,均达到了显著性水平,表明模型自变量和因变量具有相关性^[25]。在相关性分析模型中, R^2 越大,模型相关性越高,拟合度越强,回归效果越优^[26]。模型 5 与模型 6 的 R^2 为 0.747,是 6 种模型中最大值,表明模型 5 和模型 6 与其他 4 种模型相比,自变量和因变量的相关性最大,拟合度最高,模型的回归效果最优。两种模型的回归系数及显著性检验如表 3 所示。表中 B 为未标准化系数。

表 3 模型 5 和模型 6 回归系数及显著性检验分析

Tab.3 Regression coefficient and significance test analysis result of model 5 and model 6							
模型	参数	常量	环境 温度	相对 湿度	光照 强度	头部最 高温度	腿部最 高温度
5	B	38.440	-0.038	-0.014	0.034	0.025	
	t	63.971	-4.467	-17.326	3.805	4.939	
	p	0	0	0	0	0	
6	B	38.350	-0.039	-0.014	0.035	0.024	0.003
	t	58.507	-4.410	-17.216	3.818	3.500	0.390
	p	0	0	0	0	0	0.697

模型 6 经过显著性检验发现除腿部最高温度外,其他 4 种变量的 p 值均小于 0.01,表明该 4 种变量对因变量具有显著影响,不能去除,但腿部最高温

度的显著性为 0.697,大于 0.05,表明该变量对因变量的影响不显著,相关性较弱。模型 5 经过显著性检验发现,各项回归系数的 p 值均远小于 0.01,表明各项变量都对因变量有显著影响,不能剔除。

根据表 3 得到模型 5 与模型 6 的多元线性回归模型分别为

$$y' = 38.44 - 0.038x_1 - 0.014x_2 + 0.034x_3 + 0.025x_4$$

(3)

$$y' = 38.35 - 0.039x_1 - 0.014x_2 + 0.035x_3 + 0.024x_4 + 0.003x_5$$

(4)

式中 y' ——翅下温度,℃

x_1 、 x_2 、 x_3 、 x_4 、 x_5 ——环境温度、环境相对湿度、光照强度、头部最高温度、腿部最高温度

进一步比较 2 个模型的优良,模型 5 与模型 6 对测试组 50 组数据进行拟合。将拟合值 y' 与真实值 y 进行对比,并计算相对误差。其中模型 5 在训练组的平均相对误差为 0.32%,测试组的平均相对误差是 0.35%;模型 6 在训练组的平均相对误差为 0.32%,测试组的平均相对误差为 0.33%。对比可知,模型 6 的拟合度优于模型 5 的拟合度,虽然腿部最高温度与翅下温度的相关性较弱,但对于模型的拟合度有一定的优势。

选定模型 6 作为多元线性回归模型,表 4 是模型 6 的部分训练组数据,从表中可得,该模型具有较高的精确度,反演效果良好。在训练组中,该模型的最大相对误差不超过 0.49%,相对误差的平均值为 0.30%。在测试组中相对误差的平均值为 0.33%。图 7 为 50 组测试组数据的真实值与拟合值的对比图。

表 4 模型 6 对翅下温度处理的相对误差结果

Tab.4 Relative error of model 6 for temperature under wing							
序 号	真实 值/℃	预测 值/℃	相对 误差/%	序 号	真实 值/℃	预测 值/℃	相对 误差/%
1	39.2	39.259 6	0.15	11	40.0	40.025 9	0.06
2	39.5	39.382 1	0.30	12	40.2	40.003 4	0.49
3	39.2	39.374 6	0.45	13	40.0	39.945 5	0.14
4	39.3	39.307 1	0.02	14	40.1	40.088 0	0.03
5	39.3	39.329 6	0.08	15	40.1	40.033 0	0.17
6	39.3	39.407 1	0.27	16	40.0	40.020 5	0.05
7	39.4	39.302 1	0.25	17	40.2	40.048 0	0.38
8	39.4	39.503 5	0.26	18	40.2	40.082 4	0.29
9	39.6	39.546 0	0.14	19	40.0	40.057 4	0.14
10	39.7	39.563 5	0.34	20	40.0	40.062 4	0.16

3.2 基于 BP 神经网络的反演模型

基于神经网络的多元回归分析是一种非参数、




图 7 模型 6 测试组真实值与拟合值对比

Fig. 7 Curves of true value and fitted value of test group of model 6

非线性的方法,结合了神经网络与多元回归分析两方面的优势。其中 BP 神经网络是一种按照误差逆向传播算法训练的多层前馈神经网络,被大量应用于现实任务^[27]。

本试验所用的 BP 神经网络模型为 3 层拓扑结构,包括输入层、隐含层和输出层^[28]。在本试验中有 5 个主要影响因素作为 BP 神经网络的输入变量,因此输入层节点为环境温度、环境相对湿度、光照强度、头部最高温度和腿部最高温度,即输入层包含 5 个神经元。输出层的神经元数为 1,即为目标变量翅下温度,BP 神经网络结构图如图 8 所示。其中隐含层神经元个数待定。




图 8 BP 神经网络结构图

Fig. 8 Structure diagram of BP neural network

在模型中选取 Sigmoid 函数作为前向传播的激活函数,其中 Sigmoid 函数计算公式如下

$$S(x)=\frac{1}{1+e^{-x}} \tag{5}$$

式中 $S(x)$ ——输出特征值
 x ——输入特征值

本试验使用 TensorFlow 作为神经网络的基本框架^[29],在 Pyhton 2.0 环境下完成模型建立。BP 神经网络的程序使用 sklearn 库中的标准化模块对数据进行归一化预处理。使用 TensorFlow 建立 BP 网络神经模型,并按图 9 所示流程完成模型的训练。

选取 850 组数据进行训练,50 组数据作为测试集,在训练中观察迭代次数和收敛情况,动态调整学习速率、目标误差、最大迭代次数等参数。最终确定隐含层的神经元数量为 50 个,最终的网络拓扑结构为 $5 \times 50 \times 1$ 。在此基础上,使用 TensorFlow 中带有




图 9 模型训练流程图

Fig. 9 Flowchart of model training

的随机数常数生成函数帮助建立 BP 神经网络的权值和阈值。使用梯度下降法进行神经网络的反向传播优化。最终确定神经网络的学习速率为 0.01,目标误差为 0.005,最大迭代次数为 30 000 次,网络成功收敛并达到目标误差要求,最终完成模型的建立。

模型在训练组中平均相对误差为 0.24%,表 5 是训练组部分数据。对 50 组测试数据进行拟合,得到拟合值 y' ,将拟合值 y' 与真实值 y 进行对比,验证模型的准确性。该模型的最大相对误差不超过 0.46%,相对误差的平均值为 0.29%,图 10 是 50 组测试组数据的真实值与拟合值对比图。

表 5 BP 神经网络反演模型对翅下温度处理的相对误差

Tab. 5 Relative error of BP neural network inversion model for temperature under wing

序号	真实值/℃	预测值/℃	相对误差/%	序号	真实值/℃	预测值/℃	相对误差/%
1	39.5	39.638 7	0.35	11	40.1	40.184 4	0.21
2	39.6	39.595 2	0.01	12	40.1	40.130 1	0.08
3	39.5	39.615 9	0.29	13	40.0	40.113 3	0.28
4	39.4	39.579 3	0.46	14	40.2	40.144 5	0.14
5	39.6	39.723 1	0.31	15	40.2	40.181 0	0.05
6	39.7	39.655 5	0.11	16	39.6	39.623 8	0.06
7	39.5	39.652 3	0.39	17	39.6	39.626 8	0.07
8	39.6	39.623 8	0.06	18	39.7	39.637 6	0.16
9	39.6	39.626 8	0.07	19	39.7	39.645 8	0.14
10	39.6	39.642 0	0.11	20	39.5	39.449 3	0.13

3.3 两种模型的对比分析

分析结果表明,在训练组中,多元线性回归模型相对误差的平均值为 0.30%,BP 神经网络模型相




图 10 BP 神经网络反演模型的测试组真实值与拟合值对比

Fig.10 Curves of true value and fitted value of test group of back propagcotton neural network model

对误差的平均值为 0.24%。两种模型的拟合度都比较高,但 BP 神经网络模型的拟合度更优于多元线性回归模型。在 50 组测试数据中,多元线性回归模型相对误差的平均值为 0.33%,BP 神经网络模型的相对误差的平均值为 0.29%。对比可知,对于白羽肉鸡翅下温度的预测,BP 神经网络模型的准确性优于多元线性回归模型。

基于 BP 神经网络模型的反演模型相较于多元线性回归模型,具有更优良的拟合度、良好的稳定性和准确性。

4 结论

- (1) 基于深层卷积神经网络,建立鸡只头部与腿部准确识别模型,可以在鸡只热红外图像上剔除鸡只其他裸露部位的影响,准确识别出鸡只头部与腿部温度。在测试集中查准率与查全率分别达到 96.77% 和 100%。
- (2) 多元线性回归反演模型和基于 BP 神经网络的反演模型在测试集上的相对误差分别为 0.33% 和 0.29%,基于 BP 神经网络的反演模型具有更高的准确性,可以准确检测肉鸡体温。

参 考 文 献

[1] 何东健,刘冬,赵凯旋. 精准畜牧业中动物信息智能感知与行为检测研究进展[J/OL]. 农业机械学报, 2016, 47(5): 231 - 244.
HE Dongjian, LIU Dong, ZHAO Kaixuan. Review of perceiving animal information and behavior in precision livestock farming [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(5):231 - 244. http://www.j-sam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20160532&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2016.05.032. (in Chinese)

[2] 何东健,刘畅,熊虹婷. 奶牛体温植入式传感器与实时监测系统设计与试验[J/OL]. 农业机械学报, 2018, 49(12): 202 - 209.
HE Dongjian, LIU Chang, XIONG Hongting. Design and experiment of implantable sensor and real-time detection system for temperature monitoring of cow [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(12):202 - 209. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20181225&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2018.12.025. (in Chinese)

[3] 柏广宇,刘龙申,沈明霞,等. 基于无线传感器网络的母猪体温实时监测节点研制[J]. 南京农业大学学报, 2014, 37(5):128 - 134.
BAI Guangyu, LIU Longshen, SHEN Mingxia, et al. Design of sow body temperature monitoring node based on wireless sensor network[J]. Journal of Nanjing Agricultural University, 2014, 37(5):128 - 134. (in Chinese)

[4] 胡家骏. 红外非接触测温系统设计与实现[D]. 哈尔滨:黑龙江大学,2016.

[5] MCMANUS C, TANURE C B, PERIPOLLI V, et al. Infrared thermography in animal production: an overview[J]. Computers and Electronics in Agriculture, 2016, 123:10 - 16.

[6] 周丽萍,陈志,陈达,等. 基于改进 Otsu 算法的生猪热红外图像耳根特征区域检测[J/OL]. 农业机械学报,2016, 47(4): 228 - 232,14.
ZHOU Liping, CHEN Zhi, CHEN Da,et al. Pig ear root detection based on adapted Otsu[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(4):228 - 232,14. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20160430&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2016.04.030. (in Chinese)

[7] LU M, HE J, CHEN C, et al. An automatic ear base temperature extraction method for top view piglet thermal image[J]. Computers and Electronics in Agriculture, 2018, 155:339 - 347.

[8] AMEZCUA R, WALSH S, LUIMES P H, et al. Infrared thermography to evaluate lameness in pregnant sows[J]. Canadian Veterinary Journal La Revue Vétérinaire Canadienne, 2014, 55(3): 268 - 272.

[9] CAROLINA B D F A, HERNANDO O V W, RAQUEL Q C, et al. Surface temperature of ewes during estrous cycle measured by infrared thermography[J]. Theriogenology, 2018, 119:245 - 251.

[10] RAINWATER L K, PACHECO J M, PACKER C, et al. Detection of foot-and-mouth disease virus infected cattle using infrared thermography[J]. Veterinary Journal, 2009, 180(3):317 - 324.

[11] SCHAEFER A L, COOK N J, BENCH C, et al. The non-invasive and automated detection of bovine respiratory disease onset in receiver calves using infrared thermography[J]. Research in Veterinary Science, 2012, 93(2):928 - 935.

[12] ZHANG Z, ZHANG H, LIU T. Study on body temperature detection of pig based on infrared technology: a review[J].

- Artificial Intelligence in Agriculture, 2019, 1: 14 – 26.
- [13] 刘烨虹, 刘修林, 王福杰, 等. 红外热成像技术在畜禽疾病检测中的应用[J]. 中国家禽, 2018, 40(5): 70 – 72.
- [14] 刘修林, 王福杰, 刘烨虹, 等. 病理与健康蛋鸡体表温度的对比研究[J]. 中国家禽, 2017, 39(2): 53 – 56.
- [15] COOK N J, SMYKOT A B, HOLM D E, et al. Assessing feather cover of laying hens by infrared thermography[J]. The Journal of Applied Poultry Research, 2006, 15(2): 274 – 279.
- [16] JACOB F G, BARACHO M D S, NÄÄS I D A, et al. The use of infrared thermography in the identification of pododermatitis in broilers[J]. Engenharia Agrícola, 2016, 36(2): 253 – 259.
- [17] EDGAR J L, NICOL C J, PUGH C A, et al. Surface temperature changes in response to handling in domestic chickens[J]. Physiology & Behavior, 2013, 119: 195 – 200.
- [18] 杨威. 蛋鸡穿戴式无线体温感知设备的开发及体温监测实验研究[D]. 杭州: 浙江大学, 2017.
- [19] 陆辉山, 刘修林, 刘烨虹, 等. 蛋鸡体表温度与翼下温度的关系模型研究[J]. 中国家禽, 2018, 40(1): 56 – 58.
- [20] SOERENSEN D, PEDERSEN L. Infrared skin temperature measurements for monitoring health in pigs: a review[J]. Acta Veterinaria Scandinavica, 2015, 57(1): 5.
- [21] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229 – 1251.
ZHOU Feiyan, JIN Linpeng, DONG Jun. Review of convolutional neural network[J]. Chinese Journal of Computers, 2017, 40(6): 1229 – 1251. (in Chinese)
- [22] 卢宏涛, 张秦川. 深度卷积神经网络在计算机视觉中的应用研究综述[J]. 数据采集与处理, 2016, 31(1): 1 – 17.
LU Hongtao, ZHANG Qinchuan. Application of deep convolutional neural network in computer vision[J]. Journal of Data Acquisition and Processing, 2016, 31(1): 1 – 17. (in Chinese)
- [23] 沈明霞, 太猛, CEDRIC Okinda, 等. 基于深层卷积神经网络的初生仔猪目标实时检测方法[J/OL]. 农业机械学报, 2019, 50(8): 270 – 279.
SHEN Mingxia, TAI Meng, CEDRIC Okinda, et al. Real-time detection method of newborn piglets based on deep convolution neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(8): 270 – 279. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20190830&flag=1. DOI: 10.6041/j.issn.1000-1298.2019.08.030. (in Chinese)
- [24] 周文萱, 胡龙桃, 张敏, 等. 基于YOLO的小型动物识别系统设计[J]. 计算机时代, 2019(3): 22 – 25.
ZHOU Wenxuan, HU Longtao, ZHANG Min, et al. Design of YOLO-based small animal recognition system[J]. Computer Era, 2019(3): 22 – 25. (in Chinese)
- [25] 宋小园, 朱仲元, 刘艳伟, 等. 通径分析在SPSS逐步线性回归中的实现[J]. 干旱区研究, 2016, 33(1): 108 – 113.
- [26] 顾刘金. 应用SPSS软件实现多重线性回归分析[J]. 预防医学, 2018, 30(3): 323 – 324.
- [27] 汤立涛, 莫杨辉. 基于BP神经网络与多元回归的公路客运量预测研究[J]. 交通科技, 2017(5): 123 – 126.
- [28] 瞿英, 王冕, 董文旭, 等. 基于BP神经网络的农田大气氨浓度预测[J]. 中国生态农业学报, 2019, 27(4): 519 – 528.
QU Ying, WANG Mian, DONG Wenxu, et al. Prediction of atmospheric ammonia concentration in farmlands using BP neural network[J]. Chinese Journal of Eco-Agriculture, 2019, 27(4): 519 – 528. (in Chinese)
- [29] 曹学晨, 张顺堂. 基于ARIMA模型和BP人工神经网络的产品质量预测[J]. 价值工程, 2018, 37(35): 198 – 201.
CAO Xuechen, ZHANG Shuntang. Product quality prediction based on ARIMA model and BP artificial neural network[J]. Value Engineering, 2018, 37(35): 198 – 201. (in Chinese)