第42卷 第3期　　华 中 农 业 大 学 学 报　　Vol.42 No.3
2023年 5月　　Journal of Huazhong Agricultural University　　May 2023,57～62

徐迪红,韩宏鑫,刘小磊,等.基于局部红外图像的种猪核心温度反演[J].华中农业大学学报,2023,42(3):57-62.
DOI:10.13300/j.cnki.hnlkxb.2023.03.007

基于局部红外图像的种猪核心温度反演

徐迪红[1],韩宏鑫[1],刘小磊[2],赵书红[2],黎煊[1,3]

1.华中农业大学工学院/农业农村部智慧养殖技术重点实验室,武汉 430070;
2.湖北洪山实验室,武汉 430070;3.华中农业大学深圳营养与健康研究院/
中国农业科学院深圳农业基因组研究所/岭南现代农业科学与技术广东省实验室深圳分中心,深圳 518000

摘要　为了获取种猪的核心体温,收集大白猪、长白猪、大白×长白二元杂3个品种共108头母猪样本,使用手持式红外热像仪获取种猪眼睛、耳根、脖子、肩部、前背、后背、臀尖、尾根、外阴、臀部、腹部共11个部位的红外图像信息;通过温度、湿度、风速传感器获取相应猪场的环境信息。利用基于5×4嵌套交叉验证对数据进行样本集划分,并采用标准化及独热编码方式对数据进行预处理,分别建立基于红外图像技术的种猪核心温度与局部红外图像及环境因素的最小二乘支持向量机(LSSVR)、支持向量机、随机森林以及岭回归定量分析模型。通过验证确定LSSVR模型为表现最优的模型,模型决定系数R^2为0.639,RMSE、MAE分别为0.133、0.110 ℃。为了提升模型拟合效果,增加了猪品种、妊娠时间、是否发情以及采集时段(上、下午)4个可能的影响因素,结果显示,除了种猪品种对模型结果没有贡献,其他因素使模型R^2分别提高了4%、8%、10%,最终模型R^2为0.773,RMSE、MAE分别为0.106、0.09 ℃。表明增加妊娠时间、是否发情以及采集时段(上、下午)3个因素,可以明显地增强模型的拟合度,模型更加精确,可作为种猪核心温度反演的一个因素。

关键词　种猪体温;红外热成像;独热编码;快速检测;智慧养殖

中图分类号　S818.9　　**文献标识码**　A　　**文章编号**　1000-2421(2023)03-0057-06

在种猪健康养殖过程中,种猪核心体温是评估其健康状况以及预防疾病的重要指标之一[1-2]。传统测量体温的方式主要是使用水银温度计或电子温度计测量种猪的直肠温度,但该方法需要消耗大量人力以及时间成本,难以满足我国规模化养猪业的需求[3]。而且传统接触式测温会对种猪产生应激,不利于种猪的健康生长,应激也会使得种猪体温发生小范围的波动导致所测量的体温数据不准确。

近年来,具有无应激、简单快速、且不会带来种猪间疾病交叉感染风险等特点的红外热成像技术[4-6]成为非接触式的新型测温方式,且被认为是畜禽养殖行业中最有前途的技术方法之一[7]。但是红外测温不能直接获取种猪的直肠温度,仅能得到种猪体表温度,而体表温度并不能真正反映种猪的生理状态[8],因此需要探索体表温度与直肠温度之间的回归模型,并通过增加更多的可能影响因素进一步提高模型精度,从而实现对种猪体温的准确评估。前人对此也进行了较多研究[3,7-8],但目前来看仍存在模型精度不高、泛化性不强等缺点。准确预测种猪体温对种猪健康状况的准确评估以及疾病的及时发现具有重要意义。

本研究采用红外图像技术,获取种猪实验样本体表局部红外图像信息,采用传统核心体温测量方法,建立种猪核心体温与种猪眼睛[9-10]、耳根、脖子、肩部、前背、后背、臀尖、尾根、外阴、臀部、腹部共11个部位[8,11]和环境因素的定量分析模型,并对模型进行验证,旨在探究采用红外成像技术检测种猪核心体温的可行性,以期为种猪的核心体温非接触快速检测提供新的思路和依据。

1　材料与方法

1.1　数据的采集

试验于2021年7月20日在广西某猪场展开,分别对大白猪、长白猪、大白×长白二元杂3个品种共

收稿日期:2022-10-18
基金项目:武汉市生物育种重大专项(2022021302024853);湖北省科技重大专项(2022ABA002);中央高校基本科研业务费专项(2662020GXPY009);华中农业大学-中国农业科学院深圳农业基因组研究所合作基金项目(SZYJY2022031)
徐迪红,E-mail:xudihong@mail.hzau.edu.cn
通信作者:黎煊,E-mail:lx@mail.hzau.edu.cn

108头母猪数据，包括环境因素（温度、湿度、风速）和母猪体温的采集以及母猪各个部位的红外图像进行采集。试验母猪包括发情初期的母猪和妊娠母猪，其中妊娠母猪有不同的孕育时间，分别为孕育约30 d、孕育约60 d以及孕育约90 d。每天分上午（08:30—11:30）和下午（14:30—17:30）2个时间段采集数据。

1）环境因素数据的采集。试验采集的环境因素数据主要包括环境温度、湿度、风速。使用热线式风速风量计（AR866A，香港希玛仪表集团有限公司）测量风速，精度为±10%，测量范围为0.3～30 m/s。用温湿度记录仪（COS-03，山东仁科测控技术有限公司）测量温、湿度，其中温度的精度为±0.2 ℃，测量范围为−40～80 ℃，湿度精度为±2% RH（相对湿度relative humidity），测量范围为0～100% RH。测量时将温湿度记录仪的外置探头与热线式风速风量计的传感器探头放在一起，置于距离母猪正上方40～50 cm处。温度、湿度、风速每个因素数据测量2次取平均值。

2）体表局部红外图像的采集。手持式红外热像仪（C640，武汉高德智感科技有限公司）测温精度为±1 ℃或±1%。将其测温参数中的距离设置为1 m，同时在拍摄时保证红外热像仪摄像头与母猪各个部位之间的距离为1 m左右。

试验猪场采用的是限位栏饲养，因此猪常见的姿势主要有站、坐、趴、躺4种[12]，且本次试验的母猪多为妊娠母猪，除了短暂的进食期间母猪处于站立状态，其他大部分时间妊娠母猪均处于趴、躺休息的状态。因此采取当母猪处于趴躺状态时进行红外图像的采集。

前人的研究表明，猪的耳根、脖子等体表温度与直肠温度具有相关性[10]，本次试验为了从母猪体表温度中获取尽可能多的信息，采集了眼睛、耳根、脖子、肩部、前背、后背、臀尖、尾根、外阴、臀部、腹部共11个部位。本研究通过武汉高德智感科技有限公司提供的红外图像分析软件GuideInfraredAnalysis进行红外温度信息的提取，具体步骤是：将红外图像导入软件中，再从红外图像中框选出目标区域，如图1所示，软件自动获取所框选目标区域中的所有温度值信息后，再将温度值信息导出保存。在提取体表温度时，受低温噪声严重影响而导致体表温度信息失真的母猪属于异常数据，如图2所示，应将其删除，不计入总数据。

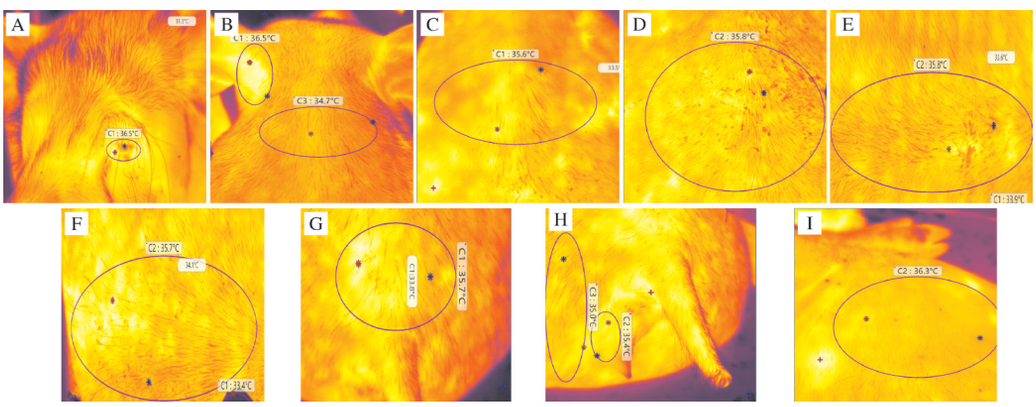

A.眼睛 Eye；B.耳根/脖子 Ears/Neck；C.肩部 Shoulder；D.前背 Front back；E.后背 Back；F.臀尖 Hip tip；G.尾根 Tail root；H.外阴/臀部 Vulva/Buttocks；I.腹部 Abdomen.

图1 种猪采集的各个部位

Fig.1 All parts collected by breeding pigs

3）种猪体温测量。种猪体温一般指直肠温度。为了保证直肠温度测量的精度，本试验采用兽用水银温度计（安徽方达药械股份有限公司）对试验母猪进行体温测量，其精度为±0.1 ℃。测量时，将温度计紧贴直肠内壁缓慢插入直肠内约6～8 cm，5 min后读取示数并记录数据。每头母猪重复上述步骤2次，取2次测量值平均值。

1.2 数据预处理与模型的建立

为了避免原始变量量纲和数量级对模型结果的影响，对原始变量进行标准化预处理。本试验除了考虑温度、湿度、风速等环境因素对猪体温的影响，还考虑了猪品种、妊娠时间、发情以及采集时段（上下午）对体温的影响。

试验分别在上午（08:30—11:30）和下午（14:30—17:30）2个时间段对猪直肠温度以及体表红外温度数据进行采集，因此采用独热编码（OneHotEncoder）的方式编码上午、下午分类变量，即设置1个二维的向量，向量的第1个分量为上午，第2个

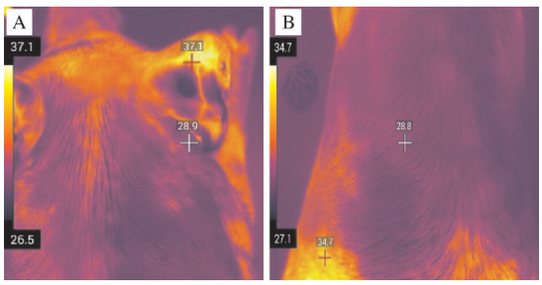

A. 耳根、脖子、肩 Ears, neck, shoulder; B. 背 Back.

图 2　受低温噪声水严重影响的母猪红外图像

Fig.2　Infrared image of breeding pigs seriously affected by low temperature noise water

分量为下午，如果上午采集数据，则第 1 个分量为 1，第 2 个分量为 0；如果下午采集数据，则第 1 个分量为 0，第 2 个分量为 1，后续编码类似。设 T_i 为数据增加采集时段上的特征维度分量，具体如式(1)表示：

$$T_i=\begin{cases}1 & \text{当采样时间为}i\text{时}\\ 0 & \text{否则}\end{cases} \tag{1}$$

其中，$i=1, 2$ 分别代表上午、下午。

母猪的发情状态能够显著影响直肠温度和体表温度[3]，在发情初期母猪的体温会显著升高[13-14]，区别于不发情的母猪。因此同样采用独热编码的方式处理该分类变量，增加 1 个是否发情的特征维度 E_i，具体如式(2)表示：

$$E_i=\begin{cases}1 & \text{当发情状态为}i\text{时}\\ 0 & \text{否则}\end{cases} \tag{2}$$

其中，$i=1, 2$ 分别代表发情、不发情。

与此同时，也增加 1 个不同妊娠时间的特征维度 G_i，同样采用独热编码的方式处理该分类变量，具体如式(3)表示：

$$G_i=\begin{cases}1 & \text{当妊娠时间为}i\text{时}\\ 0 & \text{否则}\end{cases} \tag{3}$$

其中，$i=1, 2, 3, 4$ 分别代表无妊娠、妊娠约 30 d、妊娠约 60 d、妊娠约 90 d。

本次试验的母猪分别是大白猪、长白猪、大白×长白二元杂 3 个品种，不同品种的母猪体表毛发密集程度不一样，进而可能影响到母猪体表以及直肠温度，因此为挖掘数据更多有用的信息，提高模型精度，同样采用独热编码的方式处理该分类变量，增加猪品种的特征维度 B_i，具体如式(4)表示：

$$B_i=\begin{cases}1 & \text{当品种为}i\text{时}\\ 0 & \text{否则}\end{cases} \tag{4}$$

其中，$i=1, 2, 3$，分别代表大白猪、长白猪、大白×长白二元杂。

在原始数据经过标准预处理后，利用 5×4 嵌套交叉验证将数据集划分为训练集和验证集，分别建立 LSSVR、SVR、RF 以及 RR 模型，通过比较分析获得最优模型。通过增加 4 个可能的影响因素，包括猪品种 B_i、妊娠时间 G_i、是否发情 E_i 以及采集时段（上下午）T_i，分析其对模型结果的影响，并建立种猪局部红外图像与种猪核心体温的定量分析模型。

1.3　模型评价方法

决定系数[15]（coefficient of determination，R^2）、均方根误差（root mean square error，RMSE）和平均绝对误差（mean absolute error，MAE）被用作模型性能的评价指标。决定系数 R^2 是评价回归模型的主要指标，表示回归模型对自变量变化的解释能力，所以 R^2 越大代表模型性能越好。RMSE 和 MAE 反映了直肠温度预测值和实际值之间的误差，RMSE 对较大误差非常敏感，RMSE 越小，表示模型预测结果精确度越高。MAE 将各次测量的绝对误差取绝对值后再求平均值，能更好地反映预测值误差的实际情况。同时使用 RMSE 和 MAE 有助于更好地分析误差情况，避免个别误差值造成 RMSE 过大。

2　结果与分析

2.1　数据集的划分

本试验采用嵌套交叉验证方法，外层交叉验证选择 5 折，内层交叉验证选择 4 折。本试验嵌套交叉验证的具体流程如下：

(1)获得预处理后的数据集 D。(2)对数据集 D 进行外层 5 折交叉。为了尽可能地保证每个子集数据分布的一致性，根据直肠温度分布直方图按比例分层采样将数据集 D 划分为 5 个大小相似的互斥子集。然后，每次用 4 个子集的并集作为训练集 D^*，余下的子集作为测试集 T^*。外层 5 折交叉的结果共获得 5 组训练集 D^* 与测试集 T^*。(3)对训练集 D^* 进行内层 4 折交叉，数据集划分方式同流程步骤(2)，将每折的数据集划分为训练子集、验证子集。然后设定一组超参数组合空间，对训练集 D^* 进行 4 折交叉验证，每一组超参组合获得 4 次验证的平均结果，对比不同超参组合下的平均验证结果，选择平均验证结果最好的超参组合，该组合即为最优超参数组合。(4)将该最优超参数组合在训练集 D^* 上进行训练，即可获得该最优超参组合下的最优模型。然后用测试集 T^* 对最优模型进行测试，获得外层 5 折交叉下这一折的测试结果并保存。(5)对外层 5 折交叉获得的每一折重复上述步骤(2)、(3)，获得每折测试集的测试结果并

对所有折的测试结果取均值。该均值即为评估该学习算法性能的指标。

2.2 模型的建立与验证

以11个部位的最大温度和3个环境因素共计14个特征作为回归模型的输入特征，并以母猪的直肠温度为标签，通过嵌套交叉验证划分数据集，建立岭回归(RR)模型、集成学习随机森林(RF)模型、支持向量机(SVR)模型和它的改进版本最小二乘支持向量机(LSSVR)模型，模型结果如表1所示，并以此进行模型的对比与选择。

表1 模型的统计结果

Table 1 Statistical results of the models

预测模型 Prediction model	训练集R^2 Train R^2	交叉验证R^2 Cross validation R^2	测试集 Test		
			R^2	RMSE/℃	MAE/℃
LSSVR	0.712	0.633	0.639	0.133	0.110
SVR	0.687	0.571	0.515	0.139	0.114
RF	0.895	0.457	0.459	0.147	0.120
RR	0.704	0.562	0.568	0.132	0.109

比较4个模型，LSSVR模型的测试集表现最好，具有较高的决定系数R^2和较低的RMSE、MAE，其R^2为0.639，RMSE、MAE分别为0.133、0.110 ℃，由此可见，LSSVR模型在本试验小样本数据集上表现出很好的拟合性能。

相较于其他模型，RF模型所表现的性能最差，其测试集R^2为0.459，RMSE、MAE分别为0.147、0.120 ℃，相较于LSSVR模型R^2降低了28.2%，RMSE、MAE分别升高了10.5%、9.1%。而且可以看到RF模型的训练集R^2为0.895，测试集R^2为0.459，训练集R^2比测试集R^2高出0.436，也即RF模型在本试验数据集上存在严重的过拟合问题。

值得注意的是RR模型性能仅次于LSSVR模型，其测试集R^2为0.568，RMSE、MAE分别为0.132、0.109 ℃，虽然R^2比LSSVR模型低了11.1%，但其RMSE、MAE与LSSVR模型相差并不大。

与此同时，SVR模型的R^2为0.515，RMSE、MAE分别为0.139、0.114 ℃，相较于LSSVR模型R^2降低了19.4%，RMSE和MAE分别升高了4.5%、3.6%，也即同样适用于小数据集建模的SVR模型所表现出的模型性能却不如LSSVR模型，这也说明了SVR的改进版本LSSVR相较于SVR在母猪体温预测方面具有更强的泛化能力，因此，在后续特征增加的研究中，以具有最优模型性能的LSSVR模型为基础进行相关研究。

2.3 特征增加对模型性能影响分析

本研究探讨影响母猪体温的因素，这些因素包括猪品种B_i、妊娠时间G_i、是否发情E_i以及采集时段(上下午)T_i。这些分类变量均采用独热编码的方式将其编码，然后输入到LSSVR回归模型中。为了探索所增加的变量对模型的影响，先以不加入B_i、G_i、E_i以及T_i变量的模型作为对照，然后逐步地加入B_i、G_i、E_i、T_i变量，最终模型的结果如表2所示。

表2 增加变量后的模型统计结果

Table 2 Statistical results of the model after adding variables

增加的变量 Adding variable	训练集R^2 Train R^2	交叉验证R^2 Cross validation R^2	测试集 Test		
			R^2	RMSE/℃	MAE/℃
基础变量 Basic variable	0.712	0.633	0.639	0.133	0.110
仅加B_i Basic variable+B_i	0.715	0.620	0.626	0.137	0.112
仅加G_i Basic variable+G_i	0.761	0.665	0.664	0.128	0.107
仅加E_i Basic variable+E_i	0.748	0.667	0.691	0.125	0.105
仅加T_i Basic variable+T_i	0.789	0.691	0.701	0.119	0.102
加G_i、E_i、T_i Basic variable+G_i+E_i+T_i	0.827	0.742	0.773	0.106	0.090

从表2可以清晰看到，相较于不增加变量，除了增加的种猪品种B_i特征没有使得模型精度提升外，妊娠时间G_i、是否发情E_i以及采集时段(上下午)T_i均使得模型精度进一步提升，也即增加的特征使得模型R^2进一步提高，RMSE、MAE进一步降低。其中，仅增加变量妊娠时间G_i的模型R^2为0.664，RMSE、MAE分别为0.128、0.107 ℃，仅增加变量是否发情E_i的模型R^2为0.691，RMSE、MAE分别为0.125、0.105 ℃，仅增加变量采集时段(上下午)T_i的模型R^2为0.701，RMSE、MAE分别为0.119、0.102 ℃，相较于不增加变量的R^2分别提高了4%、8%、10%，RMSE分别降低了4%、6%、11%，MAE分别降低了3%、5%、7%。可以得出，就仅增加单个变量而言，采集时段(上下午)T_i对模型精度的提高最明显，可能是因为猪上午、下午体温变化所致，也可能是因为母猪上午进食时活动较多，下午不进食、

活动较少而引起体温变化所致，但可以肯定的是特征 T_i 确实能提高模型精度。

值得注意的是，增加猪品种 B_i 的模型 R^2、RMSE、MAE 分别为 0.626、0.137 ℃、0.112 ℃，相较于不加变量的模型 R^2 反而降低了 2%，RMSE、MAE 分别升高了 3%、2%。这说明该特征的增加并没提高模型精度，反而使得模型精度降低了，也即猪品种 B_i 对模型并无贡献，反而由于该无关变量的引入导致原来的模型精度降低。因此，不再考虑猪品种 B_i 特征，将其他特征即妊娠时间 G_i、是否发情 E_i 以及采集时段（上下午）T_i 全部加入到模型中，得到的模型 R^2 为 0.773，RMSE、MAE 分别为 0.106、0.09 ℃，相较于不加变量 R^2 提高了 21%，RMSE、MAE 分别降低了 21%、18%。可以看到所增加的变量妊娠时间 G_i、是否发情 E_i 以及采集时段（上下午）T_i 使得模型精度有了较大的提升。

3 讨　论

本研究针对种猪核心体温的检测任务，提出了一种基于局部红外图像的非接触式检测方法。将种猪体表局部温度和环境因素作为回归模型的输入特征，建立与直肠核心温度之间的多种回归模型，得到改进版本 LSSVR 模型具有更强的泛化能力；使用独热编码方式编码猪品种、妊娠时间、是否发情以及采集时段 4 个可能影响因素，并与局部红外图像及环境参数相融合，提高了回归精度。试验结果表明，在 LSSVR 模型基础上，增加的 4 个可能的影响因素，除了猪品种对模型结果没有贡献，其他因素使得模型 R^2 分别提高了 4%、8%、10%，最终模型 R^2 为 0.773，RMSE、MAE 分别为 0.106、0.09 ℃。

健康评估、疾病预防与妊娠预测都离不开快速准确的猪体核心温度检测，非接触式测量对规模化、集约化的养殖需求具有一定的指导性。本研究方法采用的模型获取参数较为方便，适用于各种便携式的可移动平台，满足规模化作业。在今后的研究中可以探索更多种猪的生化指标、年龄等可能的影响因素特征，建立泛化能力更好的算法模型，以实现更精确的检测效果。

参考文献 References

[1] PETRY A, MCGILVRAY W, RAKHSHANDEH A R, et al. Technical note: assessment of an alternative technique for measuring body temperature in pigs [J]. Journal of animal science, 2017, 95(7): 3270-3274.

[2] 王德福，黄会男，张洪建，等. 生猪养殖设施工程技术研究现状与发展分析[J]. 农业机械学报，2018，49(11)：1-14. WANG D F, HUANG H N, ZHANG H J, et al. Analysis of research status and development on engineering technology of swine farming facilities [J]. Transactions of the CSAM, 2018, 49(11): 1-14 (in Chinese with English abstract).

[3] 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 Y X, WANG Y L, GAO X F, et al. Temperature changes during estrus in swine was studied by infrared temperature measurement device [J]. Chinese journal of animal and veterinary sciences, 2016, 47(1): 85-91 (in Chinese with English abstract).

[4] AHIRWAR M K, KATAKTALWARE M A, PUSHPADASS H A, et al. Scrotal infrared digital thermography predicts effects of thermal stress on buffalo (*Bubalus bubalis*) semen[J]. Journal of thermal biology, 2018, 78: 51-57.

[5] BASAK J K, ARULMOZHI E, KHAN F, et al. Assessment of the influence of environmental variables on pig's body temperature using ANN and MLR models[J]. Indian journal of animal research, 2020, 54(9): 1165-1170.

[6] 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. LIU Y H, LIU X L, WANG F J, et al. Application of infrared thermography in the detection of livestock and poultry diseases [J]. China poultry, 2018, 40(5): 70-72 (in Chinese).

[7] ZHENG S L, ZHOU C F, JIANG X P, et al. Progress on infrared imaging technology in animal production: a review [J/OL]. Sensors (Basel, Switzerland), 2022, 22(3): 705 [2022-10-18]. https://doi.org/10.3390/s22030705.

[8] KAMMERSGAARD T S, MALMKVIST J, PEDERSEN L J. Infrared thermography: a non-invasive tool to evaluate thermal status of neonatal pigs based on surface temperature[J]. Animal, 2013, 7(12): 2026-2034.

[9] SOERENSEN D D, CLAUSEN S, MERCER J B, et al. Determining the emissivity of pig skin for accurate infrared thermography [J]. Computers and electronics in agriculture, 2014, 109: 52-58.

[10] SOERENSEN D D, PEDERSEN L J. Infrared skin temperature measurements for monitoring health in pigs: a review[J/OL]. Acta veterinaria scandinavica, 2015, 57(1): 5[2022-10-18]. https://doi.org/10.1186/s13028-015-0094-2.

[11] ZHANG Z Q, ZHANG H, LIU T H. Study on body temperature detection of pig based on infrared technology: a review[J]. Artificial intelligence in agriculture, 2019, 1: 14-26.

[12] 李哲，田建艳，郑晟，等. 基于 MPU6050 和 HMC5883L 的猪的姿态检测[J]. 江苏农业科学，2016，44(2)：434-437. LI Z, TIAN J Y, ZHENG S, et al. Attitude detection of pigs based on MPU6050 and HMC5883L [J]. Jiangsu agricultural sciences, 2016, 44(2): 434-437 (in Chinese).

[13] SIMÕES V G, LYAZRHI F, PICARD-HAGEN N, et al. Varia-

tions 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.

[14] 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.

[15] 岳继博, 杨贵军, 冯海宽. 基于随机森林算法的冬小麦生物量遥感估算模型对比[J]. 农业工程学报, 2016, 32(18): 175-182. YUE J B, YANG G J, FENG H K. Comparative of remote sensing estimation models of winter wheat biomass based on random forest algorithm[J]. Transactions of the CSAE, 2016, 32(18): 175-182(in Chinese with English abstract).

Inversion of core temperature of breeding pigs based on local infrared images

XU Dihong[1], HAN Hongxin[1], LIU Xiaolei[2], ZHAO Shuhong[2], LI Xuan[1,3]

1. *College of Engineering, Huazhong Agricultural University/ Key Laboratory of Smart Farming for Agricultural Animals, Ministry of Agriculture and Rural Affairs, Wuhan* 430070, *China*;
2. *Hubei Hongshan Laboratory, Wuhan* 430070, *China*;
3. *Shenzhen Institute of Nutrition and Health, Huazhong Agricultural University/ Agricultural Genomics Institute at Shenzhen, Chinese Academy of Agricultural Sciences/ Shenzhen Branch, Guangdong Laboratory for Lingnan Modern Agriculture, Shenzhen* 518000, *China*

Abstract To obtain the core body temperature of breeding pigs, a total of 108 female pigs from three breeds, Yorkshire, Landrace, and Yorkshire×Landrace hybrids were collected. A handheld infrared thermal imager was used to obtain infrared images of 11 body parts, including the eyes, ears, neck, shoulders, front back, hind back, rump, tail, genital area, hindquarters, and abdomen. Environmental information of the corresponding pig farm, including temperature, humidity, and wind speed, was obtained through temperature, humidity, and wind speed sensors. The data was divided into training and testing sets using a nested 5×4 cross-validation method. The preprocessed data was then used to build quantitative analysis models, including the least squares support vector regression (LSSVR), support vector machine (SVM), random forest (RF), and ridge regression methods based on infrared image processing technology, as well as the local infrared imaging and environmental factors of breeding pigs. The LSSVR model was determined to be the best-performing model with a coefficient of determination (R^2) of 0.639, and the root mean squared error (RMSE) and mean absolute error (MAE) were 0.133 and 0.110 ℃, respectively. To improve the model's fitting effect, four possible influencing factors, including pig breed, pregnancy period, estrus, and sampling time (morning or afternoon), were added. The results showed that except for pig breed, other factors increased the model's performance by 4%, 8% and 10%, respectively. Finally, the R^2 of the optimized model was 0.773 with an RMSE and MAE of 0.106 and 0.09 ℃, respectively. These results indicate that adding pregnancy period, estrus, and sampling time as factors can significantly improve the model's fitting degree, making it more accurate and therefore useful as a factor for core body temperature inversion of breeding pigs.

Keywords breeding pig temperature; infrared thermal imaging; One-Hot Encoder; fast detection; smart farming

(责任编辑:边书京)