

基于 MFO-LSTM 的母猪发情行为识别

王 凯¹, 刘春红^{1,2}, 段青玲^{1,2,3*}

(1. 中国农业大学信息与电气工程学院, 北京 100083; 2. 北京市农业物联网工程技术研究中心, 北京 100083; 3. 农业农村部精准农业技术集成科学试验基地(畜牧业), 北京 100083)

摘 要: 及时准确识别母猪的发情行为可以有效增加受胎率和产仔量, 对提高养殖企业的繁育水平和经济效益具有重要意义。该研究针对生猪养殖过程中母猪发情行为识别存在主观性强、智能化水平低、假警报和错误率高、识别不及时等问题, 提出了一种基于飞蛾扑火算法(Moth-Flame Optimization, MFO)优化长短时记忆网络(Long Short Term Memory, LSTM)的母猪发情行为识别方法。利用安装在母猪颈部的姿态传感器获得母猪姿态数据, 然后使用姿态数据训练 MFO-LSTM 姿态分类模型, 将母猪姿态分为立姿、卧姿和爬跨 3 类。通过对姿态分类结果进行分析, 确定以爬跨行为和活动量 2 个特征作为发情行为识别依据, 使用 MFO-LSTM 分类算法判断母猪是否发情。以山西省太原市杏花岭区五丰养殖场的试验数据对该方法进行验证, 结果表明, 该方法在以 30 min 为发情行为识别时间时的识别效果最好, 发情行为识别的错误率为 13.43%, 召回率为 90.63%, 特效性为 81.63%, 与已有的母猪发情行为识别方法相比错误率降低了 80% 以上。该方法在保证识别准确率的情况下有效降低了错误率, 可满足母猪养殖生产过程中发情行为自动识别要求。

关键词: 行为; 监测; 算法; 母猪; 发情; 长短时记忆网络; 飞蛾扑火算法

doi: 10.11975/j.issn.1002-6819.2020.14.026

中图分类号: TP391; S828

文献标志码: A

文章编号: 1002-6819(2020)-14-0211-09

王凯, 刘春红, 段青玲. 基于 MFO-LSTM 的母猪发情行为识别[J]. 农业工程学报, 2020, 36(14): 211-219. doi: 10.11975/j.issn.1002-6819.2020.14.026 <http://www.tcsae.org>

Wang Kai, Liu Chunhong, Duan Qingling. Identification of sow oestrus behavior based on MFO-LSTM[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2020, 36(14): 211-219. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.2020.14.026 <http://www.tcsae.org>

0 引 言

中国是世界养猪大国和猪肉消费大国, 2019 年中国猪肉产量 5 404 万 t, 占肉类总产量的 55.62%, 因此, 生猪养殖业健康发展对维护国家粮食安全具有重要意义^[1]。在生猪养殖中, 母猪的繁育能力是影响养殖效益的关键因素之一, 母猪年均提供断奶仔猪数(Pigs Weaned Per Sow Per Year, PSY)是衡量母猪繁育能力的重要指标。2018 年美国生猪养殖行业平均 PSY 为 24, 而中国平均 PSY 为 18, 说明中国的生猪养殖水平与发达国家相比还存在明显差距^[2-3]。母猪的繁育能力与发情、配种、妊娠和分娩过程密不可分, 其发情期持续时间为 20~84 h, 而最佳交配和输精时间在发情后 20~30 h^[4-5]。因此, 及时准确地识别母猪发情行为能够实现及时配种, 提高配种成功率, 有效减少空怀和返情情况, 有助于提高母猪繁育能力。

当母猪发情时, 由于生理变化会产生一系列的行为特征, 如卧立不安, 啃圈爬栏, 走动频繁, 活动量(一

段时间内母猪处于活跃状态的时长)明显增多, 主动接近公猪, 公猪经过或“按背测试”时表现出“静立反射”, 食欲略减, 出现爬跨行为, 体温较平常有所上升, 发出“求偶歌声”, 外阴肿胀呈红色, 流出透明黏液等^[4-5]。其中, 部分行为特征如采食量变化、母猪频繁访问公猪、活动量增加、爬跨行为等可通过物联网感知设备获取, 从而为母猪发情行为自动识别提供依据。

目前, 国内外研究人员对基于物联网的母猪发情行为识别进行了一些研究, 主要是基于母猪访问公猪频率^[6-7]和母猪采食行为^[8]进行识别。Ostensen 等^[6]使用射频识别(Radio Frequency Identification, RFID)扫描器记录通过“瞭望洞”与公猪接触的母猪耳标号, 并统计出 24 和 72 h 内母猪访问公猪的频率和时长, 构建基于一阶马尔可夫概率的多过程动态线性模型进行母猪发情行为识别。以 24 h 为发情行为识别时间的试验结果错误率 95.0%, 召回率 60.7%, 特效性 98.8%; 72 h 的试验结果错误率 97.1%, 召回率 89.2%, 特效性 96.9%。Cornou 等^[8]通过自动饲喂器记录母猪进入自动饲喂器的采食次序、猪群个体数量和每日进食周期等参数, 输入单变量动态线性模型, 利用 V-mask 控制图识别母猪是否发情, 此方法的发情行为识别, 召回率 75.0%, 特效性 95.4%。

综上, 目前母猪发情行为识别方法还存在以下问题: 一是错误率高, 其主要原因是信息源过于单一, 基于单特征的发情行为识别难以准确识别发情状况。错误率高意味着假警报数量多, 过多的假警报会浪费工人的时间

收稿日期: 2019-12-11 修订日期: 2020-06-09

基金项目: 国家重点研发计划(2016YFD0700200); 国家高技术研究发展计划(863 计划)资助项目(2013AA102306)

作者简介: 王凯, 研究方向为智能信息处理。

Email: S20173081212@alu.cau.edu.cn

*通信作者: 段青玲, 博士, 教授, 主要从事智能信息处理研究。

Email: dqing@cau.edu.cn

来寻找母猪和测试母猪是否发情, 高假警报状况下的检测成本超过了每天人工监控所有母猪的成本^[6]。二是现有研究均需要至少母猪发情 24 h 后才可以识别, 及时性有待提高。

姿态传感器是一种三维运动姿态测量设备, 可以采集运动对象的三轴加速度、角速度、欧拉角、磁场数据和四元数等三维姿态数据, 与三轴加速度传感器相比能够更加全面、精确地描述运动物体的姿态^[9-10]。目前尚未见使用姿态传感器在牲畜行为识别领域的研究, 但已有基于三轴加速度传感器进行牲畜行为识别的研究, 如哺乳母猪高危活动识别^[11]、山羊(躺卧、站立或慢走、采食和跨跳)行为识别^[12]、奶牛健康状况监测^[13]、奶牛发情行为识别^[13-15]、奶牛(反刍、进食和饮水)行为识别^[16]、母猪姿态分类^[17-21]以及妊娠母猪产前行为识别和分娩时间估计^[22-23]等, 但关于母猪发情行为识别还未见应用。

基于此, 本文提出了一种基于飞蛾扑火算法(Moth-Flame Optimization, MFO)优化长短时记忆网络(Long Short Term Memory, LSTM)的母猪发情行为识别方法。首先, 通过姿态传感器采集母猪姿态数据, 使用MFO算法优化LSTM模型参数, 训练得到姿态分类器, 将母猪姿态分为立姿、卧姿和爬跨3类, 从姿态分类结果中提取母猪活动量和爬跨行为特征, 输入并训练得到发情行为识别模型, 以期降低母猪发情行为识别错误率, 提升母猪繁育水平, 提高生猪养殖效益。

1 试验材料与方法

1.1 试验数据采集和预处理

生猪姿态数据于2019年4月19—30日采集自山西省太原市杏花岭区五丰养殖场。安装试验设备的圈舍内有10个南北朝向的圈栏, 圈栏大小为6 m×5 m×1.2 m, 每个圈栏可容纳5~6头母猪。试验对象为大长白猪, 共6头母猪和6头公猪, 母猪中有4头处于发情期。试验共使用6个圈栏, 每个圈栏内放置1头公猪和1头母猪, 试验期间猪在圈舍内自由活动。

在母猪颈部上安装型号为WT901WIFIC的维特智能WIFI姿态传感器, 每个传感器有唯一ID编号, 且与母猪的耳标号一一对应。姿态传感器同时采集三轴加速度、角速度、角度、磁场和四元数5类数据, 采集频率为1次/s。传感器通过符合IEEE 802.11标准的无线局域网连接到猪舍内布置的无线路由器, 该路由器连接因特网, 采集到的数据通过无线局域网传输到数据服务器, 如图1所示。为避免出现数据碰撞问题, 舍内布置2个路由器, 每个路由器上绑定的姿态传感器设备不超过20个。圈舍内安装型号为DS-2CD3T86FWDV2-I3S的海康威视高清网络摄像头, 可24 h监视圈舍, 视频内容为人工标记母猪姿态分类标签提供依据。

采集到母猪姿态数据后对照视频和人工监控记录对传感器数据进行检查, 对传感器移动、脱落以及部分传感器损坏状态下采集的错误数据进行删除, 共采集到1 042 207个母猪姿态样本数据。为避免量纲差异和样本排列顺序影

响模型分类效果, 采用最小-最大值法对数据集中每个变量进行归一化处理, 采用随机索引打乱样本顺序。

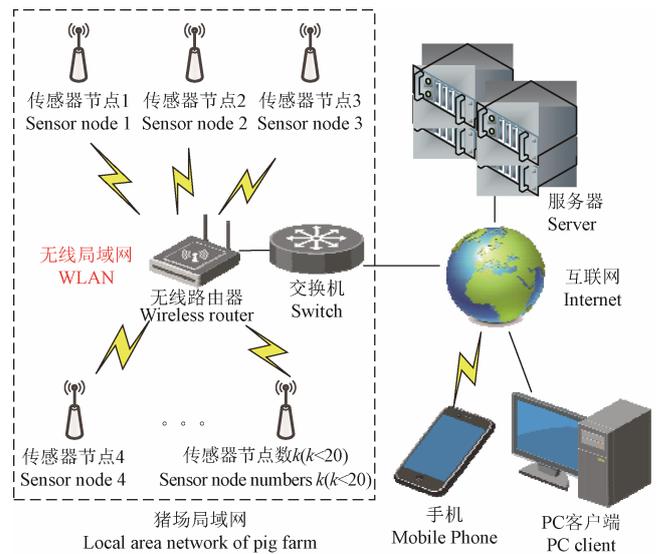


图1 传感器数据传输示意图

Fig.1 Schematic diagram of sensor data transmission

1.2 基于MFO-LSTM的母猪发情行为识别方法

1.2.1 算法流程

基于MFO-LSTM的母猪发情行为识别流程如下:

1) 数据采集和预处理。利用姿态传感器采集描述母猪运动状态的三轴加速度、角速度、角度、四元数和磁场5类数据, 对数据进行预处理, 构建姿态数据集。

2) 基于MFO-LSTM的母猪姿态分类模型构建。采用MFO优化LSTM算法的第一、二层隐含层神经元数目、最大训练周期、分块尺寸和学习率; 将姿态数据训练集作为输入, 对照视频标记的姿态作为标签, 训练基于MFO-LSTM的母猪姿态分类模型; 最终将母猪姿态分为立姿、卧姿和爬跨3类。

3) 母猪爬跨行为和活动量特征提取。统计母猪姿态分类结果, 得到3类姿态在发情行为识别时间内的累计时长, 并从中提取爬跨行为特征和活动量特征。

4) 基于MFO-LSTM的母猪发情行为识别模型构建。将提取的发情行为识别特征作为模型输入, 以猪场管理记录中母猪的发情状态作为标签, 训练发情行为识别模型, 实现母猪发情行为的识别。

1.2.2 基于MFO-LSTM的母猪姿态分类

爬跨行为和活动量是母猪发情的重要行为特征, 而提取这2个特征的前提是对母猪的姿态进行分类。本文采用基于MFO-LSTM的分类算法将母猪姿态分为立姿、卧姿和爬跨3类。立姿是指母猪正常活动中的行走和站立姿态, 卧姿是指母猪休息时的立卧姿和侧卧姿, 爬跨是指发情母猪骑到其他猪脊背上的姿态。3种姿态中立姿和爬跨属于活跃姿态, 卧姿属于不活跃姿态。

LSTM是一种改进的循环神经网络, 可以有效解决梯度消失和梯度爆炸问题^[24], 已广泛应用于时间序列数据的预测^[25-27]和分类^[28]等领域。本文LSTM神经网络各层结构如图2所示。

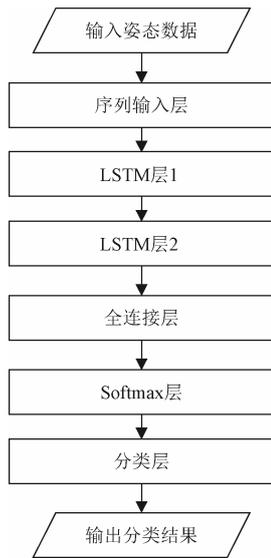


图 2 LSTM 网络层次结构

Fig. 2 Network hierarchy structure of Long Short Term Memory (LSTM)

由于 LSTM 使用过程中需要调节多个参数，且参数取值对模型预测和分类效果影响较大，人工搜索参数费时费力，因此需要目标规划算法辅助参数寻优^[27]。MFO 算法相对于传统的遗传算法、粒子群优化算法等目标规划算法具有寻优速度快、不容易陷入局部最优的优势^[29]。因此本文使用 MFO 算法优化 LSTM 模型参数。

MFO 算法优化 LSTM 参数过程如下：

1) 确定待优化参数的个数和值域。设定 LSTM 中待优化参数为第一层和第二层隐含层神经元数目、最大训练周期、分块尺寸和学习率，并依次根据这 5 个参数值域设置其参数上下限数组 lb 和 ub ：

$$lb = [lb_1, lb_2, lb_3, \dots, lb_{n-1}, lb_n] \quad (1)$$

$$ub = [ub_1, ub_2, ub_3, \dots, ub_{n-1}, ub_n] \quad (2)$$

式中 n 为待优化参数的个数； lb_i 为第 i 个待优化参数下限； ub_i 为第 i 个待优化参数上限。

2) 使用 LSTM 模型评价指标准确率 Accuracy 作为适应度函数输出；

3) 使用随机函数初始化蛾子矩阵。根据飞蛾矩阵和适应度函数计算飞蛾适应度向量；

4) 判断是否达到最大迭代次数，若当前迭代次数超过最大迭代次数转到步骤 5)，否则更新种群并继续寻优。采用文献[29]中的对数螺旋函数 S 作为飞蛾位置更新机制。对数螺旋函数 S 的计算公式如下：

$$S(M_i, F_j) = D_i \cdot e^{bt} \cdot \cos(2\pi t) + F_j \quad (3)$$

$$D_i = |F_j - M_i| \quad (4)$$

式中 D_i 表示第 i 只飞蛾到第 j 个火焰的距离； M_i 表示第 i 只飞蛾； F_j 表示第 j 个火焰； b 为 S 的常数； t 为 $[-1,1]$ 中的随机数，该参数定义飞蛾的下一个位置与火焰的距离， $t = -1$ 为离火焰最近的位置， $t = 1$ 为离火焰最远的位置。

5) 输出参数寻优。

经过上述步骤后得到 MFO-LSTM 姿态分类模型。具

体流程如图 3 所示。

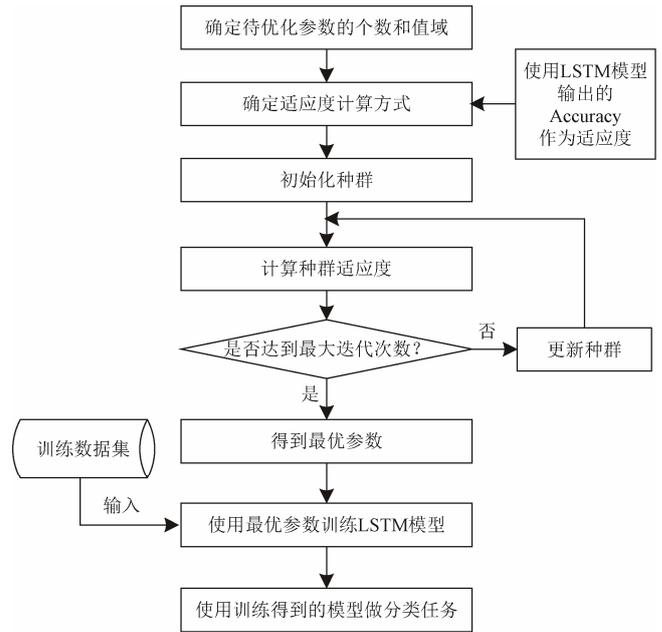


图 3 MFO 优化 LSTM 算法参数流程图

Fig. 3 Flow chart of LSTM parameters optimization by Moth-Flame Optimization

在分类模型的训练过程中，各类样本数量的均衡性会直接影响模型的泛化性能。母猪姿态数据集中各类样本数量差异较大，属于样本不均衡数据集。为了避免因数据集不均衡导致过拟合问题的出现并减少模型训练时间，在对数据集进行预处理后，按照立姿、卧姿和爬跨 3 种姿态样本数量相同的原则从姿态数据中随机抽取 190 050 条母猪姿态数据用于母猪姿态分类模型的训练和性能验证。

将随机抽取的姿态数据按 8:2 划分训练集和测试集。使用姿态数据训练集 (152 040 个姿态样本) 训练得到基于 MFO-LSTM 的母猪姿态分类模型。将测试集 (38 010 个姿态样本) 输入到模型中，得到姿态分类结果。将模型给出的姿态分类结果和对照视频标记的标签进行对比，计算模型评价指标，检验姿态分类模型的性能。

1.2.3 母猪发情行为识别特征提取

发情母猪活动量显著增加并出现爬跨行为，本文使用爬跨行为和活动量 2 个特征作为发情行为识别依据。

1) 姿态分类结果的获取

在训练得到基于 MFO-LSTM 的母猪姿态分类模型并验证其可靠性之后，使用该模型对采集得到的 1 042 207 个母猪姿态样本数据进行姿态分类，将姿态分类结果整理为姿态分类结果矩阵 $R_{posture}$ ，用于后续发情行为识别特征提取。

$$R_{posture} = \begin{bmatrix} T_1 & P_1 & H_1 \\ T_2 & P_2 & H_2 \\ \dots & \dots & \dots \\ T_i & P_i & H_i \\ \dots & \dots & \dots \\ T_{n_0} & P_{n_0} & H_{n_0} \end{bmatrix} \quad (5)$$

式中 n_0 为姿态数据集样本总数, 即 1 042 207; T_i 为数据采集时间, 格式为“YYYY-MM-dd hh:ss:mm”; P_i 为母猪耳标号; H_i 为姿态分类模型输出的结果。

2) 发情行为识别时间确定

提取母猪发情行为识别的特征需要对母猪姿态分类的矩阵 $R_{posture}$ 进行统计。在统计过程中, 需要确定发情行为识别时间 (以下简称“ T_{inv} ”), 该参数控制发情行为识别操作触发的频率。 T_{inv} 越小, 说明发情行为识别所需要的时间越短, 即模型可以更及时识别发情行为。

T_{inv} 的取值影响发情行为识别模型的准确性和及时性。过小的 T_{inv} 会导致发情行为识别操作频繁触发, 频繁的操作会增加计算机负担, 还可能造成大多数爬跨行为无法完整的落在发情识别时间内。 T_{inv} 过小也会使被用于发情行为特征提取的姿态数据样本数量减少, 使得姿态统计结果不足以反映母猪活动的状况, 从而导致发情行为识别的准确性降低。因此, 在保证发情行为检测准确性的同时也要考虑及时性, 过大的 T_{inv} (如 24 和 72 h) 可能会导致发情行为识别不及时。但不可以一味地降低 T_{inv} (追求高及时性而忽略了准确性。在考虑提高及时性的同时应兼顾错误率、召回率和特效性等反映发情行为识别准确性的指标。

为了确定 T_{inv} 参数下限, 本文统计了姿态分类结果中的每次完整爬跨行为的持续时长 T_c 。本文定义一次完整爬跨行为的识别规则如下:

- ① 在姿态数据集中, 若爬跨姿态持续 10 s 以上, 则认为爬跨行为开始;
- ② 将第一条爬跨姿态数据的采集时间 (精确到 s) 作为爬跨行为的开始时刻;
- ③ 爬跨行为开始一段时间后, 当其他姿态 (卧姿、立姿等) 出现且持续时间超过 10 s 时认为爬跨状态终止, 反之则认为爬跨行为一直在持续;
- ④ 将最后一条爬跨姿态数据的采集时间作为爬跨行为的终止时刻;
- ⑤ 从爬跨行为开始到结束这一段时间内的行为称为一次完整的爬跨行为。

按照上述规则识别得到母猪的爬跨行为持续时长后, 通过绘制散点图得到其分布规律, 按照 90% 的比例确定 T_{inv} 下限 $T_{inv_{min}}$ 。母猪发情周期和配种时间均按小时 (h) 计算^[4-5]。

为尽早识别出发情行为和配种时间推算, 确定 T_{inv} 上限 $T_{inv_{max}}$ 的规则是

$$T_{inv_{max}} \leq 1 \text{ h} \quad (6)$$

3) 爬跨行为特征和活动量特征提取

母猪发情时会出现爬跨行为。本文以母猪发情行为识别时间为频率对姿态分类结果矩阵 $R_{posture}$ 数据进行统计, 得出发情行为识别时间内爬跨姿态累计时长 $D_{mounting}$, 进而得到爬跨姿态累计时长占发情行为识别时间的百分比 ($U, \%$) 并将其作为爬跨行为特征。

$$U = \frac{D_{mounting}}{N} \times 100\% \quad (7)$$

式中 N 为发情行为识别时间长度, s; $D_{mounting}$ 为发情行为

识别时间内爬跨姿态累计时长, s。

母猪大部分时间都处于趴卧和睡眠状态, 只有少部分时间起身走动、饮水、吃食和进行其他活动, 但母猪在发情时会躁动不安, 活动量增加。本文对姿态分类结果矩阵 $R_{posture}$ 数据进行统计, 采用发情行为识别时间内活跃姿态累计时长占发情行为识别时间的百分比 ($A, \%$) 和不活跃姿态的累计时长占发情行为识别时间的百分比 ($I, \%$) 作为活动量特征。

$$A = \frac{D_{standing} + D_{mounting}}{N} \times 100\% \quad (8)$$

$$I = \frac{D_{lying}}{N} \times 100\% \quad (9)$$

式中 $D_{standing}$ 为发情行为识别时间内立姿累计时长, s; D_{lying} 为发情行为识别时间内卧姿累计时长, s。

确定发情行为识别时间的上下限之后, 按照上下限 $T_{inv_{max}}$ 和 $T_{inv_{min}}$, 统计发情行为识别时间内 3 种姿态时长, 计算发情行为识别特征矩阵 C 。

$$C = \begin{bmatrix} T_{start1} & T_{end1} & P_1 & U_1 & A_1 & I_1 \\ T_{start2} & T_{end2} & P_2 & U_2 & A_2 & I_2 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ T_{starti} & T_{endi} & P_i & U_i & A_i & I_i \\ \dots & \dots & \dots & \dots & \dots & \dots \\ T_{startm} & T_{endm} & P_m & U_m & A_m & I_m \end{bmatrix} \quad (10)$$

式中 m 为姿态统计结果的记录数, 即对 1 042 207 个姿态数据每 T_{inv} 进行一次姿态统计, 每一次统计得到一条统计结果即为矩阵 C 的一行, 矩阵的总行数为 m ; T_{starti} 和 T_{endi} 分别为发情行为识别时间的起始和终止时刻; U_i 、 A_i 和 I_i 分别为从 T_{starti} 开始到 T_{endi} 结束这段时间内爬跨行为特征和活动量特征的计算结果数值。

1.2.4 基于 MFO-LSTM 的母猪发情行为识别方法

本文采用爬跨行为和活动量两个特征识别发情行为。将包含两个特征的特征矩阵 C 和发情行为识别标签 Q 合并为模型输入矩阵 $Input$ 。将矩阵 $Input$ 作为母猪发情行为识别数据集, 对其进行归一化和无序处理后按照 8:2 的比例划分为训练集和测试集。

$$Input = \begin{bmatrix} T_{start1} & T_{end1} & P_1 & U_1 & A_1 & I_1 & Q_1 \\ T_{start2} & T_{end2} & P_2 & U_2 & A_2 & I_2 & Q_2 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ T_{starti} & T_{endi} & P_i & U_i & A_i & I_i & Q_i \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ T_{startm} & T_{endm} & P_m & U_m & A_m & I_m & Q_m \end{bmatrix} \quad (11)$$

式中 Q_i 为根据猪场管理记录人工标记的发情行为识别结果, 用于发情行为识别模型的训练, 其取值范围为 $Q = \{\text{发情, 不发情}\}$ 。

2 试验结果与分析

2.1 试验环境和评价指标

本文算法基于 Matlab 2018a 在 Windows 7 64 位操作系统环境下实现。LSTM 程序使用 Matlab 深度学习工具

箱完成。MFO 程序使用文献[29]的 Matlab 工具箱完成。支持向量机 (Support Vector Machine, SVM) 程序使用 Libsvm 工具箱完成。

根据机器学习分类问题常用评价指标^[16,30]和相关文献^[6,8,31], 本文确定母猪姿态分类试验评价指标为准确率、召回率和 F1 值, 母猪发情行为识别试验评价指标为错误率、召回率和特异性。在母猪姿态分类试验中, 当识别某一种姿态时, 正类指目标姿态, 负类指除目标姿态外其他所有姿态。在母猪发情行为识别试验中, 正类指母猪发情, 负类指母猪不发情。各个指标的含义和计算方式如下:

1) 准确率 Accuracy: 该指标从总体上反映了模型正确分类的能力, 既包括对目标类别的分类, 又包括对非目标类别的分类。准确率越高说明模型分类效果越好:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (12)$$

2) 错误率 Error Rate: 该指标描述了母猪发情识别过程中假发情警告样本数 FP 与检测到的发情样本数之间的关系, 衡量发情行为识别过程中假警报的出现情况。错误率越低说明发情行为识别过程中的假警报越少:

$$Error\ Rate = \frac{FP}{FP+TP} \times 100\% \quad (13)$$

3) 召回率 Recall: 部分发情行为识别文献中将其称之为灵敏性 Sensitivity, 该指标反映了目标类别不被漏检的概率。召回率越高说明模型的分类效果越好:

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (14)$$

4) 特异性 Specificity: 该指标反映了目标类别不被误检的概率。特异性越高说明模型的分类效果越好:

$$Specificity = \frac{TN}{FP+TN} \times 100\% \quad (15)$$

5) F1 值: 该指标同时兼顾了分类模型的精度和召回率, 是模型精度和召回率的调和平均, 该值越高说明模型的分类效果越好:

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (16)$$

$$F1 = \frac{2 \cdot Recall \cdot Precision}{Recall + Precision} \quad (17)$$

式中 TP 为将正类识别为正类的样本数; FN 为将正类识别为负类的样本数; FP 为将负类识别为正类的样本数; TN 为将负类识别为负类的样本数。

2.2 母猪姿态分类试验结果

2.2.1 MFO-LSTM 姿态分类试验结果

为了比较使用姿态传感器进行姿态测量和传统方法中使用三轴加速度传感器 2 种情况下的姿态分类效果, 本文使用姿态数据集和三轴加速度数据集进行母猪姿态分类对比试验。姿态数据集由三轴加速度、三轴角速度、三轴角度 (欧拉角)、三轴磁场和四元数 (q_0 、 q_1 、 q_2 和 q_3) 组成, 三轴加速度数据集仅包含三轴加速度。2 个数据集的姿态分类试验结果如表 1 所示。

在 MFO-LSTM 模型中, 2 个 LSTM 层的隐藏层单元

数取值范围为[30, 70]、最大训练周期取值范围为[50, 100]、分块尺寸取值范围为[20, 80]、学习率取值范围为(0, 10^{-5})。使用 LSTM 模型评价指标准确率 Accuracy 作为适应度函数的返回值。设定 MFO 算法中参与寻优的参数为 20 组 (即飞蛾数量为 20), 最大迭代次数为 25, 待优化参数个数为 5 (即维度为 5)。

表 1 基于 MFO-LSTM 的母猪姿态分类试验结果

Table 1 Results of sow posture classification based on MFO-LSTM

| 数据集 Data sets | 姿态 Postures | 准确率 Accuracy/% | 召回率 Recall/% | F1 值 F1 value |
|---|-------------|----------------|--------------|---------------|
| 姿态数据集 Posture data set | 立姿 | 97.04 | 93.80 | 93.02 |
| | 卧姿 | 97.20 | 95.07 | 95.72 |
| | 爬跨 | 99.82 | 99.92 | 99.81 |
| 三轴加速度数据集 Triaxial acceleration data set | 立姿 | 81.89 | 28.92 | 42.54 |
| | 卧姿 | 86.04 | 94.82 | 83.72 |
| | 爬跨 | 78.21 | 82.39 | 78.24 |

从表 1 中可以看出, 使用姿态数据集进行分类时, 各姿态识别的平均准确率为 98.02%, 平均召回率为 96.26%, 平均 F1 为 96.18。只使用三轴加速度数据进行姿态分类时, 各类姿态的平均识别准确率为 82.04%, 平均召回率为 68.71%, 平均 F1 为 68.16。基于本文方法并采用姿态数据集相对于传统方法采用三轴加速度数据集可以更有效区分立姿、卧姿和爬跨 3 类姿态, 可以为发情行为特征提取提供可靠数据。

2.2.2 与其他方法的姿态识别性能对比

为了验证本文方法的优越性, 使用支持向量机 (Support Vector Machine, SVM)、概率神经网络 (Probabilistic Neural Network, PNN)、学习向量量化 (Learning Vector Quantization, LVQ) 神经网络和极限学习机 (Extreme Learning Machine, ELM) 4 种方法与本文方法进行了姿态识别对比试验, 结果如表 2 所示。对比试验中各个模型参数设定如下: SVM 核函数为 RBF 函数^[16]。LVQ 竞争层神经元个数为 20, 学习率为 0.1^[32]。ELM 隐藏层神经元数为 100, 激活函数为 Sigmoid 函数^[33]。

表 2 基于 SVM、PNN、LVQ 和 ELM 方法的母猪姿态分类试验结果

Table 2 Results of sow posture classification based on SVM, PNN, LVQ and ELM methods

| 方法 Methods | 姿态 Postures | 准确率 Accuracy/% | 召回率 Recall /% | F1 值 F1 value |
|---|-------------|----------------|---------------|---------------|
| 支持向量机 Support Vector Machine (SVM) | 立姿 | 89.88 | 62.98 | 72.32 |
| | 卧姿 | 91.56 | 94.76 | 88.12 |
| | 爬跨 | 97.93 | 98.54 | 97.98 |
| 概率神经网络 Probabilistic Neural Network (PNN) | 立姿 | 88.06 | 48.64 | 63.06 |
| | 卧姿 | 89.94 | 97.76 | 86.71 |
| | 爬跨 | 97.39 | 98.75 | 97.49 |
| 学习向量量化 Learning Vector Quantization (LVQ) | 立姿 | 90.84 | 69.01 | 75.84 |
| | 卧姿 | 93.07 | 94.67 | 90.13 |
| | 爬跨 | 97.31 | 97.81 | 97.32 |
| 极限学习机 Extreme Learning Machine (ELM) | 立姿 | 92.47 | 82.48 | 82.11 |
| | 卧姿 | 95.42 | 93.97 | 93.36 |
| | 爬跨 | 96.70 | 95.90 | 96.54 |

从表 1 和表 2 中可以看出, 本文方法的各项母猪姿态分类评价指标均优于 SVM、PNN、LVQ 和 ELM 方法, 与 SVM、PNN、LVQ 和 ELM 相比本文方法具有优越性。

通过各方法对爬跨姿态的识别情况可以看出, 所有模型对爬跨姿态的识别效果均好于对立姿和卧姿好, 这是由于爬跨行为与立姿和卧姿相比特征更明显, 更容易被分类模型学习到。

通过对比使用姿态数据集和三轴加速度数据集的试验可以看出, 使用姿态数据集的姿态分类效果较好, 其原因是姿态数据中除了三轴加速度数据外, 还提供了三轴角速度、角度、磁场和四元数, 磁场数据可以对三轴加速度数据起到一定的辅助校正作用, 描述猪只运动情况的数据更加全面和准确, 从而有效降低了猪只姿态分类的错误率。

2.3 母猪发情行为识别特征提取试验结果

为了计算发情行为识别特征矩阵 C 中各个变量, 需要统计发情行为识别时间下的各姿态数量, 因此必须确定发情行为识别时间的下限 $T_{inv_{min}}$, 以确定发情行为识别时间的取值范围并最终确定其取值。通过对母猪的每一次爬跨行为持续时间长度进行统计, 将大部分爬跨行为持续时长的上限作为发情行为识别时间的下限, 以便使大多数爬跨行为可以在发情行为识别时间内完整地发生一次。通过对姿态分类结果矩阵 $R_{posture}$ 和人工对比视频分析, 确定本文实验共识别出 26 次完整的爬跨行为, 每次爬跨行为的持续时间统计结果如图 4 所示。

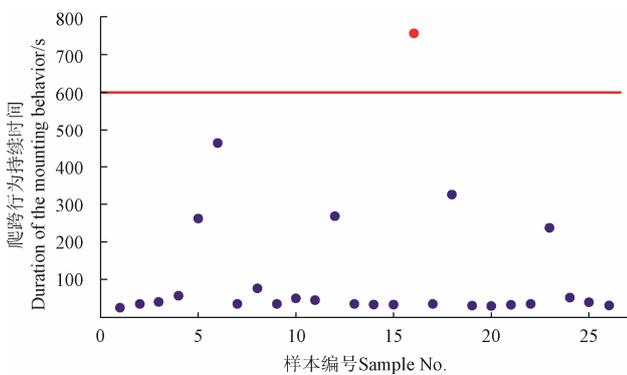


图 4 爬跨行为持续时间统计结果

Fig.4 Statistical results of duration of mounting behavior

从图 4 中可以看出, 96.29%的爬跨行为持续时间在 600 s 内。由于母猪发情周期和配种时间均按小时 (h) 计算^[4-5], 为方便配种时间的计算, 发情行为识别时间最好是 60 min (1 h) 的倍数或能被其整除。因此, 发情行为识别时间下限 $T_{inv_{min}}$ 取 10 min 较为合适。结合发情行为识别时间的上限确定发情行为识别时间的范围为 [10 min, 60 min]。

2.4 母猪发情行为识别试验结果

发情行为识别试验分为准确性验证和及时性验证。准确性验证主要检验本文方法的有效性, 即能否在保证发情行为识别准确率的同时降低错误率; 及时性验证主要是检验本文方法能否在配种前识别出母猪发情行为。

根据发情行为识别时间范围, 分别对 10、20、30、

40、50 和 60 min 的各类姿态数量进行统计, 统计结果用于发情行为识别。将不同发情行为识别时间下的 $Input$ 矩阵输入 MFO-LSTM 模型进行试验, 并比较各个发情行为识别时间下模型的性能, 以确定最佳发情行为识别时间, 试验结果如表 3 所示。

表 3 母猪发情行为识别试验结果

Table 3 Results of oestrus behavior recognition of sows

| 发情行为识别时间 Oestrus behavior recognition time/min | 错误率 Error rate/% | 召回率 Recall/% | 特效性 Specificity/% |
|--|---------------------|-----------------|----------------------|
| 10 | 27.63 | 78.57 | 60.38 |
| 20 | 19.05 | 76.58 | 67.74 |
| 30 | 13.43 | 90.63 | 81.63 |
| 40 | 20.69 | 74.19 | 82.35 |
| 50 | 18.92 | 81.08 | 74.07 |
| 60 | 15.00 | 82.93 | 64.71 |

由表 3 可知, 发情行为识别时间 T_{inv} 为 30 min 时, 发情行为识别错误率为 13.43%, 召回率为 90.63%, 特效性为 81.63%。通过对比本文方法以 30 min 为发情识别时间下的错误率和其他文献中识别方法的错误率可知, 本文方法比文献[6]中以 24 h 为发情行为识别时间的发情行为识别错误率降低了 85.86%, 比以 72 h 为发情行为识别时间的发情行为识别错误率降低了 86.16%, 比文献[8]中的发情行为识别错误率降低了 86.52%, 平均降低了 80% 以上。本文采用爬跨行为和活动量 2 个特征进行发情识别, 发情行为识别错误率与基于单特征的发情行为识别方法相比, 在保持较高的召回率和特效性的同时降低了错误率, 发情行为识别结果的可信度更高。

本文方法每 30 min 对母猪的姿态数据进行一次统计分析, 因此最少在 30 min 内就可以识别母猪发情行为。文献[6,8]是基于 24 或 72 h 时间内的数据统计分析才可以识别出母猪发情行为。母猪的最佳配种时间为发情后的 20~30 h^[4-5], 如果基于 24 或 72 h 后的数据进行发情行为识别, 在数据分析得出结论时很可能已经错过了母猪的最佳配种时机, 而使用本文方法可以在最佳配种时机到来之前识别出母猪的发情行为。经过统计和对比猪场管理记录, 使用本文方法进行发情识别, 在识别到试验母猪发情行为 18~20 h 后猪场开始进行配种工作, 为配种工作争取了更多的准备时间。本文方法可以更早、更及时地识别出母猪发情行为, 有利于最优配种时间的推算和配种工作的准备。

3 结论

针对母猪发情行为识别过程中错误率高、识别不及时的问题, 本文提出了基于 MFO-LSTM 的母猪发情行为识别方法, 主要结论如下:

1) 使用 MFO-LSTM 分类方法将母猪姿态分为立姿、卧姿和爬跨 3 种姿态。试验结果表明使用姿态数据集比只使用三轴加速度数据集姿态分类准确率更高。本文姿态分类方法的平均分类准确率为 98.02%, 平均召回率为 96.26%, 平均 F1 为 96.18, 为后续发情行为识别奠定基础;

2) 当使用 30 min 作为发情行为识别时间时, 发情行为识别错误率为 13.43%, 召回率为 90.63%, 特效性为 81.63%, 与其他已有的母猪发情行为识别方法相比错误率降低了 80%以上。本文提出的母猪发情行为识别方法具有准确及时、错误率低的优点, 适合在实际生产中推广应用。

[参 考 文 献]

- [1] 国家统计局. 2019 年国民经济和社会发展统计公报[EB/OL]. (2020-02-28) [2020-05-14]. http://www.stats.gov.cn/tjsj/zxfb/202002/t20200228_1728913.html.
- [2] 猪好多网. 世界各国养猪生产成绩比较[EB/OL]. (2020-04-24) [2020-06-09]. <https://www.yangzhu360.com/dianping/20200424/22899.html>.
- [3] 中华人民共和国农业农村部. 张兴旺同志在全国畜牧业机械化现场会上的讲话[EB/OL]. (2019-11-25) [2020-05-14]. http://www.njhs.moa.gov.cn/nyjxhqk/201911/t20191128_6332485.htm.
- [4] 张配配, 张涛, Brad Belstra, 等. 母猪的发情检测[J]. 国外畜牧学(猪与禽), 2014(6): 4-11.
Zhang Peipei, Zhang Tao, Brad Belstra, et al. Estrus detection of sow[J]. Foreign Animal Husbandry (Pig and Poultry), 2014(6): 4-11. (in Chinese with English abstract)
- [5] 桑润滋. 实用畜禽繁殖技术[M]. 北京: 金质出版社, 2008.
- [6] Ostensen T, Cornou C, Kristensen A R. Detecting oestrus by monitoring sows' visits to a boar[J]. Computers and Electronics in Agriculture, 2010, 74(1): 51-58.
- [7] Bressers H P M, Brake J H A T, Noordhuizen J P T M. Oestrus detection in group-housed sows by analysis of data on visits to the boar[J]. Applied Animal Behaviour Science, 1991, 31(3/4): 183-193.
- [8] Cornou C, Vinther J, Kristensen A R. Automatic detection of oestrus and health disorders using data from electronic sow feeders[J]. Livestock Science, 2008, 118(3): 262-271.
- [9] 侯庆余. 基于 MEMS 的资料浮标姿态传感器的设计与实现[D]. 青岛: 中国海洋大学, 2014.
Hou Qingyu. The Design and Implementation of Data Buoy Posture Sensor Based on MEMS[D]. Qingdao: Ocean University of China, 2014. (in Chinese with English abstract)
- [10] 曾唯. 微型惯性传感器应用于飞行器模型姿态测试的研究[D]. 厦门: 厦门大学, 2007.
Zeng Wei. Research on Micro Inertial Sensor Applied to Attitude Test of Aircraft Model[D]. Xiamen: Xiamen University, 2007. (in Chinese with English abstract)
- [11] 闫丽, 沈明霞, 谢秋菊, 等. 哺乳母猪高危动作识别方法研究[J]. 农业机械学报, 2016, 47(1): 266-272.
Yan Li, Shen Mingxia, Xie Qiujun, et al. Research on recognition method of lactating sows' dangerous body movement[J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(1): 266-272. (in Chinese with English abstract)
- [12] 郭东东. 基于三轴加速度传感器的山羊行为特征识别研究[D]. 太原: 太原理工大学, 2015.
Guo Dongdong. Research on 3D Acceleration Sensor Recognition for Goats' Behavior Recognition[D]. Taiyuan: Taiyuan University of Technology, 2015. (in Chinese with English abstract)
- [13] 尹令, 刘财兴, 洪添胜, 等. 基于无线传感器网络的奶牛行为特征监测系统[J]. 农业工程学报, 2010, 26(3): 203-208.
Yin Ling, Liu Caixing, Hong Tiansheng, et al. Design of system for monitoring dairy cattle's behavioral features based on wireless sensor networks[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2010, 26(3): 203-208. (in Chinese with English abstract)
- [14] 尹令, 洪添胜, 刘汉兴, 等. 结构相似子序列快速聚类算法及其在奶牛发情检测中的应用[J]. 农业工程学报, 2012, 28(15): 107-112.
Yin Ling, Hong Tiansheng, Liu Hanxing, et al. Subsequence clustering algorithm based on structural similarity and its application in cow estrus detection[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2012, 28(15): 107-112. (in Chinese with English abstract)
- [15] 田富洋, 王冉冉, 刘莫尘, 等. 基于神经网络的奶牛发情行为辨识与预测研究[J]. 农业机械学报, 2013, 44(S1): 277-281.
Tian Fuyang, Wang Ranran, Liu Mochen, et al. Oestrus detection and prediction in dairy cows based on neural networks[J]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(S1): 277-281. (in Chinese with English abstract)
- [16] 任晓惠, 刘刚, 张淼, 等. 基于支持向量机分类模型的奶牛行为识别方法[J]. 农业机械学报, 2019, 50(S1): 290-296.
Ren Xiaohui, Liu Gang, Zhang Miao, et al. Dairy cattle's behavior recognition method based on support vector machine classification model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(S1): 290-296. (in Chinese with English abstract)
- [17] 闫丽, 沈明霞, 姚文, 等. 基于 MPU6050 传感器的哺乳期母猪姿态识别方法[J]. 农业机械学报, 2015, 46(5): 279-285.
Yan Li, Shen Mingxia, Yao Wen, et al. Recognition method of lactating sows' posture based on sensor MPU6050[J].

- Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(5): 279-285. (in Chinese with English abstract)
- [18] Cornou C, Lundbye-christensen S. Classification of sows' activity types from acceleration patterns using univariate and multivariate models[J]. Computers and Electronics in Agriculture, 2010, 72(2): 53-60.
- [19] Escalante H J, Rodriguez S V, Cordero J, et al. Sow-activity classification from acceleration patterns: A machine learning approach[J]. Computers and Electronics in Agriculture, 2013, 93: 17-26.
- [20] Thompson R, Matheson S M, PLÖTZ T, et al. Porcine lie detectors: Automatic quantification of posture state and transitions in sows using inertial sensors[J]. Computers and Electronics in Agriculture, 2016, 127: 521-530.
- [21] Oczak M, Maschat K, Berckmans D, et al. Can an automated labelling method based on accelerometer data replace a human labeller? - Postural profile of farrowing sows[J]. Computers and Electronics in Agriculture, 2016, 127: 168-175.
- [22] Cornou C, Lundbye-christensen S, Kristensen A R. Modelling and monitoring sows' activity types in farrowing house using acceleration data[J]. Computers and Electronics in Agriculture, 2011, 76(2): 316-324.
- [23] 刘龙申, 沈明霞, 姚文, 等. 基于加速度传感器的母猪产前行为特征采集与分析[J]. 农业机械学报, 2013, 44(3): 192-196.
- Liu Longshen, Shen Mingxia, Yao Wen, et al. Acquisition and analysis of sows' behavior before farrowing based on acceleration sensor[J]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(3): 192-196. (in Chinese with English abstract)
- [24] Graves A. Long Short-Term Memory[M]//Studies in Computational Intelligence. Berlin: Springer-Verlag Berlin, 2012: 37-45.
- [25] 杨亮, 刘春红, 郭昱辰, 等. 基于 EMD-LSTM 的猪舍氨气浓度预测研究[J]. 农业机械学报, 2019, 50(S1): 353-360.
- Yang Liang, Liu Chunhong, Guo Yuchen, et al. Prediction of ammonia concentration in fattening piggery based on EMD-LSTM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(S1): 353-360. (in Chinese with English abstract)
- [26] 陈英义, 程倩倩, 方晓敏, 等. 主成分分析和长短时记忆神经网络预测水产养殖水体溶解氧[J]. 农业工程学报, 2018, 34(17): 183-191.
- Chen Yingyi, Cheng Qianqian, Fang Xiaomin, et al. Principal component analysis and long short-term memory neural network for predicting dissolved oxygen in water for aquaculture[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2018, 34(17): 183-191. (in Chinese with English abstract)
- [27] 李万, 冯芬玲, 蒋琦玮. 改进粒子群算法优化 LSTM 神经网络的铁路客运量预测[J]. 铁道科学与工程学报, 2018, 15(12): 3274-3280.
- Li Wan, Feng Fenling, Jiang Qiwei. Prediction for railway passenger volume based on modified PSO optimized LSTM neural network[J]. Journal of Railway Science and Engineering, 2018, 15(12): 3274-3280. (in Chinese with English abstract)
- [28] 赵明, 社会芳, 董翠翠, 等. 基于 word2vec 和 LSTM 的饮食健康文本分类研究[J]. 农业机械学报, 2017, 48(10): 202-208.
- Zhao Ming, Du Huifang, Dong Cuicui, et al. Diet health text classification based on word2vec and LSTM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(10): 202-208. (in Chinese with English abstract)
- [29] Mirjalili S. Moth-flame optimization algorithm: A novel nature-inspired heuristic paradigm[J]. Knowledge-Based Systems, 2015, 89: 228-249.
- [30] 袁培森, 任守纲, 翟肇裕, 等. 基于半监督主动学习的菊花表型分类研究[J]. 农业机械学报, 2018, 49(9): 27-34.
- Yuan Peisen, Ren Shougang, Zhai Zhaoyu, et al. Chrysanthemum phenotypic classification based on semi-supervised active learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(9): 27-34. (in Chinese with English abstract)
- [31] Cornou C. Automated oestrus detection methods in group housed sows: Review of the current methods and perspectives for development[J]. Livestock Science, 2006, 105(1-3): 1-11.
- [32] 梁武科, 彭文季, 罗兴镝. 基于 LVQ 网络的水电机组振动多故障诊断方法[J]. 农业机械学报, 2007, 38(1): 208-210.
- Liang Wuke, Peng Wenji, Luo Xingqi. Multi - fault diagnosis method of hydropower unit vibration based on LVQ network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2007, 38(1): 208-210. (in Chinese with English abstract)
- [33] 宦娟, 刘星桥. 基于 K-means 聚类 and ELM 神经网络的养殖水质溶解氧预测[J]. 农业工程学报, 2016, 32(17): 174-181.
- Huan Juan, Liu Xingqiao. Dissolved oxygen prediction in water based on K-means clustering and ELM neural network for aquaculture[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2016, 32(17): 174-181. (in Chinese with English abstract)

Identification of sow oestrus behavior based on MFO-LSTM

Wang Kai¹, Liu Chunhong^{1,2}, Duan Qingling^{1,2,3*}

(1. College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China; 2. Beijing Engineering and Technology Research Center for Internet of Things in Agriculture, Beijing 100083, China; 3. Scientific Research Base for Integrated Technologies of Precision Agriculture (Animal Husbandry), Ministry of Agriculture and Rural Affairs, Beijing 100083, China)

Abstract: Timely and accurate identification of oestrus behavior of sows can effectively increase the conception rate and litter size, which is of great significance to improve the breeding level and economic benefits of breeding enterprises. The traditional identification methods of oestrus behavior of sows have the problems of high working intensity, strong subjectivity and low automation level. Some identification methods of oestrus behavior of sows based on internet of things also have some problems, such as high false alarm times, high error rate and long recognition time. In order to solve the problems of low identification accuracy and efficiency, a oestrus behavior recognition method of sows based on Moth-Flame Optimization optimized Long Short Term Memory(MFO-LSTM) was proposed in this paper, and the verification test was carried out at WuFeng breeding farm in Xinghualing district, Taiyuan city, Shanxi Province. The posture data of sows were obtained by posture sensors installed on the neck of the sows. The posture data describing the sow's motion state contained three-axis acceleration, three-axis angular velocity, three-axis angle, three-axis magnetic field and quaternion. The collected posture data was manually marked according to the videos, and preprocessed to obtain a posture classification data set. Then, the MFO algorithm was used to optimize the numbers of first and second hidden layer neurons, maximum training period, block size and learning rate, thus, the LSTM network model was built. Postures of sows were divided into three categories, i.e. standing, lying and mounting. Through the statistics of the duration of each complete mounting behavior of the sows, the range of the recognition time of the oestrus behavior was obtained. The sows posture classification results were counted with different oestrus behavior recognition duration, and two characteristics of mounting behavior and activity were then extracted, so as to obtain the recognition feature matrix of oestrus behavior of sows. Finally, the feature matrix was input into the MFO-LSTM classification model to judge whether the sow was oestrus. The experimental results showed that the classification method of sows posture proposed could effectively distinguish the three postures of standing, lying and mounting. The classification effects of proposed method were better than that of the Support Vector Machine (SVM), Probabilistic Neural Network(PNN), Learning Vector Quantization (LVQ) and Extreme Learning Machine(ELM). The average accuracy, recall rate and F1 in the attitude data set were 98.02%, 96.26% and 96.18, respectively. On the basis of accurately identifying the sows' posture, the effect of oestrus behavior recognition based on MFO-LSTM algorithm was verified. The test results showed that the recognition effect was best when the oestrus recognition duration was 30 min at this time, the error rate, recall rate and specificity of oestrus recognition were 13.43%, 90.63% and 81.63%, respectively. The oestrus behavior of sows recognition method proposed effectively reduced the error rate while maintaining a high recall rate and specificity. Compared with other methods, the error rate was reduced by more than 80%, the oestrus behavior of sow could be recognized after 30 min of oestrus.

Keywords: behavior; monitoring; algorithms; sows; oestrus behavior; long short-term memory; moth-flame optimization