

基于面部关键点轨迹的鱼骨式挤奶厅奶牛异常行为检测方法

叶文昊^{1,2} 孔令森^{1,2} 秦雨^{1,2} 李国亮^{1,2} 韩猛立³ 赵文娟³
李嘉位^{1,2} 钟发钢³

(1. 华中农业大学信息学院, 武汉 430070; 2. 农业农村部智慧养殖技术重点实验室, 武汉 430070;

3. 新疆农垦科学院, 石河子 832000)

摘要: 挤奶过程是奶牛应激反应和动物福利问题的高发环节,对异常行为进行自动化监测对于提升挤奶管理水平和保障奶牛福利具有重要意义。针对鱼骨式挤奶厅中空间受限、多牛同时入镜、遮挡频繁以及个体轨迹易跳变等问题,本文面向鱼骨式挤奶厅特定场景,开展了基于面部关键点轨迹的奶牛异常行为检测研究。以 DeepLabCut 作为关键点感知模块,在此基础上引入栏位位置约束与牛脸朝向约束进行多牛轨迹修正,并结合场景化行为特征与规则判别实现事件级异常输出。实验结果表明,基于栏位位置和牛脸朝向的双约束融合修正可将多奶牛编号跳变次数由 18.500 次降至 0.125 次,准确率由 93.83% 提升至 99.96%;在异常行为事件级检测中,单牛异常行为事件级的精确率、召回率、漏检率和误检率分别为 96.55%、96.55%、3.45% 和 3.45%;多牛交互异常行为事件级的精确率、召回率、漏检率和误检率分别为 85.71%、100%、0 和 14.29%;关键点感知模块的精确率、召回率、平均精度均值和标准化平均误差分别达到 98.69%、98.61%、97.22% 和 5.31%。该方法为固定视角挤奶场景下的异常行为自动检测提供了一种可行方案,具有较好的可解释性和工程适用性。

关键词: 华西牛; 鱼骨式挤奶厅; 面部关键点; 异常行为检测; 轨迹修正; 规则驱动

中图分类号: TP391.4 **文献标识码:** A **文章编号:** 1000-1298(2026)15-0103-13

OSID:



Method for Detecting Abnormal Cow Behavior in Fishbone-style Milking Parlors Based on Facial Landmark Trajectories

Ye Wenhao^{1,2} Kong Lingsen^{1,2} Qin Yu^{1,2} Li Guoliang^{1,2} Han Mengli³ Zhao Wenjuan³
Li Jiawei^{1,2} Zhong Fagang³

(1. College of Informatics, Huazhong Agricultural University, Wuhan 430070, China

2. Key Laboratory of Smart Farming for Agricultural Animals, Ministry of Agriculture and Rural Affairs, Wuhan 430070, China

3. Xinjiang Academy of Agricultural and Reclamation Science, Shihezi 832000, China)

Abstract: The milking process is a high-risk phase for stress responses and animal welfare issues in dairy cows; automated monitoring of abnormal behaviors is crucial for improving milking management and ensuring cow welfare. Aiming to address the challenges in herringbone milking parlors, such as limited space, multiple cows entering the field of view simultaneously, frequent occlusions, and erratic individual trajectories, the detection of abnormal cow behaviors was investigated based on facial landmark trajectories, specifically tailored to the unique environment of herringbone milking parlors. Using DeepLabCut as the keypoint detection module, stall position constraints and cow-face orientation constraints were introduced to correct multi-cow trajectories, and combined scenario-specific behavioral features with rule-based classification to achieve event-level anomaly detection. Experimental results showed that the dual-constraint fusion correction based on stall position and cow face orientation reduced the number of keypoint ID changes for multiple cows from 18.500 to 0.125, while increasing accuracy

收稿日期: 2026-03-31 修回日期: 2026-05-28

基金项目: 国家自然科学基金项目(32402825)、多模态人工智能系统全国重点实验室开放课题(MAIS2025062)和兵团科技创新工程资金项目(NCG202503)

作者简介: 叶文昊(2001—),男,博士生,主要从事畜牧智能装备研究,E-mail: yewenhao@mail.hzau.edu.cn

通信作者: 钟发钢(1969—),男,研究员,主要从事奶牛和肉牛疫病防控研究,E-mail: zfg125@sohu.com

from 93.83% to 99.96%. In event-level detection of abnormal behavior, the precision, recall, false negative rate, and false positive rate for single-cow abnormal behavior events were 96.55%, 96.55%, 3.45%, and 3.45%, respectively. For multi-cow interactive abnormal behavior event-level detection, the precision, recall, false negative rate, and false positive rate were 85.71%, 100%, 0, and 14.29%, respectively. The keypoint detection module achieved a precision of 98.69%, a recall of 98.61%, a mean average precision of 97.22%, and a standardized mean error of 5.31%. This method can provide a viable solution for the automatic detection of abnormal behaviors in fixed-view milking scenarios, offering good interpretability and engineering applicability.

Key words: Huaxi cattle; fishbone-style milking parlor; facial landmarks; abnormal behavior detection; trajectory correction; rule-driven

0 引言

在现代奶牛生产系统中,动物福利水平与产奶量及奶品质之间具有密切关系。研究表明,良好的福利状态有助于降低皮质醇等应激激素水平,维持机体采食、反刍及休息行为的自然表达,从而保障泌乳系统的稳态,确保乳脂率、乳蛋白率等关键指标的稳定^[1-2]。相反,当奶牛遭受环境胁迫或疼痛刺激时,行为模式的异常往往先于产奶量下降或体细胞数升高等生理指标^[3]。在奶牛养殖的全流程中,挤奶环节是奶牛与机械设备、作业人员及复杂声光环境交互最为频繁的阶段,也是应激反应的高发场景。在鱼骨式挤奶厅的受限空间内,真空压力不适、乳房炎疼痛或外界惊扰极易引发奶牛的急性应激,这通常表现为头部快速上抬行为、频繁甩头以及其它持续性的异常姿态^[4]。这些异常行为不仅是动物福利受损的直接表现,还可能会引发生产安全事故,严重影响生产效率^[5]。目前针对挤奶场景的监测仍主要依赖人工巡视,这种方式不仅劳动强度大、主观性强,且在规模化养殖中难以实现对个体行为的连续、实时监控,无法满足现代牧场对生产过程可控性的需求^[6]。

奶牛行为的自动化监测相关研究主要分为接触式传感器监测与非接触式计算机视觉监测两大路径。早期的研究主要采用加速度计、计步器或颈部项圈等接触式设备,通过采集运动数据来量化奶牛的躺卧时间、行走步数及反刍频率^[7-8]。现在的工作主要沿目标检测、多目标跟踪和关键点姿态估计开展^[9],视觉研究多集中于开阔的运动场或散栏舍环境^[10],挤奶厅内牛只排列紧密、金属围栏遮挡严重,导致常规目标检测算法极易失效^[11],此外,端到端的深度学习行为识别模型通常需要大量标注数据进行训练,难以针对不同牧场灵活调整^[12]。总体来看,现有研究^[13-17]多面向开放牛舍或通道场景,针对挤奶厅内多牛密集排列、遮挡频繁和全身关键点难以获取等问题,仍缺少可解释性和工程适用

性的方法^[18]。

针对鱼骨式挤奶厅固定视角、多牛密集排列和遮挡频繁导致奶牛异常行为自动检测困难的问题,本文开展基于奶牛面部少量关键点轨迹的异常行为检测研究。基于 DeepLabCut 获取奶牛面部关键点轨迹,在此基础上研究关键点轨迹修正方法与面向挤奶管理需求的事件级异常检测。针对鱼骨式挤奶厅中多牛密集条件下关键点身份易跳变的问题,提出结合栏位位置与牛脸朝向的关键点轨迹修正方法,以提升牛只个体轨迹连续性与一致性;面向鱼骨式挤奶厅固定机位、牛只排列紧密和遮挡频繁的场景,建立基于面部少量关键点轨迹的奶牛异常行为分析流程,以适应全身姿态难以稳定获取的场景特点;面向挤奶管理需求,构建规则驱动的事件级异常判别与提取流程,以实现异常行为的结构化输出和可解释分析。

1 方法总体设计与实验条件

1.1 视频数据采集

本研究的图像视频数据采集于新疆维吾尔自治区可克达拉市洪海牧业有限公司。实验对象为泌乳期华西牛,为表述简洁,统称为奶牛。

视频数据采集场景如图 1 所示,在不影响奶牛正常挤奶生产的前提下,在鱼骨式挤奶厅两侧安装固定摄像头,从奶牛正前方对其挤奶过程中的头部行为进行视频采集。



图 1 视频数据采集场景

Fig. 1 Video data collection scenario

摄像头安装高度约为 1.5 m,与被拍摄奶牛之间的水平距离约为 5 m,拍摄视角正对挤奶奶牛头部区域。视频分辨率为 2 560 像素 × 1 440 像素,帧

率为 30 f/s, 视频存储格式为 MP4。受鱼骨式挤奶厅结构及奶牛站位影响, 单帧画面中可同时采集 7~9 头奶牛的头部图像。

1.2 视频数据集构建

实验涉及奶牛共 384 头, 共采集 6 台摄像头的视频数据, 原始视频经过裁剪处理, 仅保留奶牛处于挤奶过程中的有效片段, 构建的视频数据集总时长超过 1 500 min。由于挤奶过程中奶牛头部存在自然摆动、相互遮挡以及个体行为差异, 视频数据中包含不同视角、模糊、局部遮挡及多牛交互等复杂情况。



图 2 总体技术路线图
Fig. 2 Overall technology roadmap

2 关键点感知与异常行为检测

2.1 基于 DeepLabCut 的奶牛面部关键点感知模块

面部关键点的正确感知是奶牛异常行为检测的基础, 其检测精度与稳定性直接影响后续分析结果的可靠性^[20]。为在复杂挤奶场景下稳定获取奶牛面部关键点的时序轨迹, 选用基于深度学习的姿态估计框架 DeepLabCut, 并结合鱼骨式挤奶厅固定视角视频数据对模型进行训练与验证^[21-22]。

2.1.1 奶牛面部关键点感知模块

采用 DeepLabCut 框架对奶牛面部关键点进行检测。从原始视频数据集中人工选取 24 段具有代表性的视频片段, 每段视频时长约为 10 min。在每段视频中均匀随机抽取 30 帧图像, 共获得 720 帧标注样本, 并按比例 8:1:1 划分为训练集、验证集和测试集。所选视频均源于鱼骨式挤奶厅的实际生产场景, 覆盖头部快速运动、个体间相互遮挡、局部模糊以及两牛接触或碰撞等异常情况, 单帧画面中同

1.3 奶牛异常行为检测方法总体架构

本文构建了一套基于视频与关键点轨迹的奶牛异常行为检测方法, 方法总体架构如图 2 所示, 主要包括关键点感知与异常行为检测 2 部分。以鱼骨式挤奶厅内采集的多牛视频为输入, 采用基于 DeepLabCut 的奶牛面部关键点感知模块提取奶牛左眼、右眼和鼻尖 3 个关键点^[19], 并将其输入异常行为检测模块。异常行为检测模块包括多牛轨迹预处理、行为信号构建、异常行为判别和异常事件提取输出 4 个流程。

时包含 7~9 头奶牛。为进一步评价关键点感知模块在复杂挤奶场景下的检测稳定性, 额外构建了一个 100 帧的独立复杂场景测试集, 该测试集不参与模型训练与参数选择, 选帧时重点覆盖复杂情况。

所有实验均在以下配置的服务器上进行: Intel Xeon Silver 4310 处理器, 基频为 2.1 GHz, 12 核, 24 线程; 具有 48 GB 显存的 NVIDIA L20 GPU; 128 GB 内存。操作系统为 Windows, 实验设置采用 Python 3.10 作为编程语言, PyTorch 1.10.1 作为深度学习框架, CUDA 11.3 进行 GPU 加速计算。

本研究选取奶牛面部左眼中心、右眼中心及鼻尖中心作为关键点。训练样本的关键点标注工作通过 DeepLabCut 提供的图形化标注工具 (GUI) 完成, 所有标注帧均由专业人员人工逐帧标注, 以确保标注精度与一致性。模型训练过程中采用 DeepLabCut 默认的迁移学习策略, 在预训练网络权重的基础上进行微调。

2.1.2 评价指标

为客观全面的评价奶牛面部关键点感知模块在复杂挤奶场景下的检测完整性、定位精度及部署可行性,本文选取精确率(Precision)、召回率(Recall)、平均精度均值(Mean average precision, mAP)、标准化平均误差(Normalized mean error, NME)、单帧推理时间和模型参数量作为评价指标^[23]。

2.2 异常行为检测模块

2.2.1 关键点轨迹预处理

异常行为检测模块以关键点感知模块输出的奶牛面部关键点轨迹作为原始输入,对关键点轨迹依次进行轨迹修正、异常值处理、插值补全、平滑滤波及尺度归一化等预处理操作,从而获得连续、稳定且具有尺度一致性的关键点轨迹数据,预处理后的轨迹作为后续行为特征计算的统一输入^[24]。

2.2.2 构建行为特征

构建了基于关键点时序变化的奶牛行为特征,为后续异常行为判别提供输入。所有行为特征均由奶牛面部3个关键点(左眼中心、右眼中心及鼻尖中心)的二维轨迹计算得到。

定义视频图像坐标系如下:以视频图像左上角为坐标原点,水平方向向右为 x 轴正方向,竖直方向向下为 y 轴正方向。设左眼、右眼及鼻尖关键点在时刻 t 的二维坐标 $L(t)$ 、 $R(t)$ 、 $N(t)$ 分别为

$$\begin{cases} L(t) = (x_L(t), y_L(t)) \\ R(t) = (x_R(t), y_R(t)) \\ N(t) = (x_N(t), y_N(t)) \end{cases} \quad (1)$$

2.2.2.1 构建几何参考点

本文首先定义多个几何特征参考点,如图3所示,用于统一后续行为特征计算的空间基准。




图3 几何特征参考点
Fig.3 Geometric feature reference point

(1)眼基准点 $E(t)$

左右眼关键点在挤奶过程中相对稳定,其几何中心能够较好地反映头部整体位置。因此,本文将左右眼关键点的中点定义为眼基准点

$$E(t) = \frac{L(t) + R(t)}{2} \quad (2)$$

当某一帧中仅检测到单侧眼关键点时,采用该侧眼关键点作为眼基准点;当双眼关键点均不可用

时,眼基准点失效。眼基准点主要用于描述奶牛头部的平移运动及相对位移特征。

(2)三点中心 $C(t)$

为刻画奶牛头部绕自身中心发生的旋转行为(如摇头、甩头等),引入由3个关键点构成的几何中心,定义为

$$C(t) = \frac{L(t) + R(t) + N(t)}{3} \quad (3)$$

该几何中心可近似视为头部的旋转中心,用于后续头部旋转角及角速度等特征的计算。

(3)头部参考点 $P(t)$

在描述头部整体运动时,默认采用眼基准点作为头部参考点。当眼基准点在个别帧不可用时,依次采用单侧眼关键点或鼻尖关键点进行替代。该参考点主要用于计算头部平移速度及位移相关特征。

(4)尺度因子 S

在基于关键点轨迹的行为特征计算过程中,不同数据集可能由于摄像机安装高度、拍摄距离及分辨率差异,导致关键点位移幅度和速度等特征在数值尺度上存在差异。为增强方法在不同应用场景下的适用性,在方法设计中引入尺度因子 S ,用于对相关几何特征进行统一尺度调节。

在本文所采用的实验数据中,摄像机安装位置与拍摄参数固定,挤奶场景结构一致,且参与实验的奶牛体型差异较小,因此关键点轨迹在空间尺度上具有较好的一致性。在该条件下,行为特征无需进行额外的尺度归一化处理,尺度因子取 $S = 1$ 。当方法应用于其他拍摄条件或不同奶牛群体时,可根据实际数据特征设置相应的尺度因子 S ,以增强规则函数在不同数据集上的一致判别能力。

2.2.2.2 静态姿态特征

静态姿态特征主要用于描述奶牛头部在单帧时刻的空间构型关系,用以刻画抬头、低头及头部指向等姿态状态,特征示意图如图4所示。




图4 静态姿态特征
Fig.4 Static posture features

(1)眼间距 $d_{eye}(t)$

眼间距定义为左右眼关键点之间的欧氏距离

$$d_{eye}(t) = \| R(t) - L(t) \| \quad (4)$$

该特征可作为关键点检测稳定性的辅助参考。

(2)眼鼻距离特征 $E_N(t)$

本文构建眼鼻距离特征刻画奶牛在挤奶过程中

抬头或低头等头部俯仰行为。

$$E_N(t) = \frac{\|E(t) - N(t)\|}{S} \quad (5)$$

该特征反映鼻子相对于眼部的位置变化,经尺度归一化后可用于不同个体之间的统一分析。

(3) 鼻方向角 $\phi(t)$

针对挤奶过程中奶牛常见的左右转头、摆头行为,构建基于头部方向的姿态特征。以眼基准点为参考,定义鼻方向角为

$$\phi(t) = \arctan[2(y_N(t) - y_E(t), x_N(t) - x_E(t))] \quad (6)$$

式中 $x_E(t)$ 、 $y_E(t)$ ——眼基准点 $E(t)$ 在 t 时刻的 x 、 y 轴坐标

该特征反映奶牛头部在图像平面内的指向变化,是后续摇头类异常行为判别的重要基础特征。

2.2.2.3 动态姿态特征

动态姿态特征用于描述奶牛头部姿态随时间变化的速度与运动强度特性。

(1) 线速度 $v(t)$

头部平移线速度由头部参考点的相邻帧位移计算得到

$$v(t) = \frac{P(t) - P(t-1)}{S} \quad (7)$$

其中,速度幅值可表示为: $V(t) = \|v(t)\|$,用于反映头部整体运动的剧烈程度。

(2) 角速度 $\omega(t)$

为刻画头部旋转快慢,以 3 点中心 $C(t)$ 为旋转中心,定义头部旋转角 $\alpha(t)$ 为

$$\alpha(t) = \arctan[2(y_N(t) - y_C(t), x_N(t) - x_C(t))] \quad (8)$$

式中 $x_C(t)$ 、 $y_C(t)$ ——三点中心 $C(t)$ 在 t 时刻的 x 、 y 轴坐标

在此基础上,对相邻帧旋转角进行差分并结合视频帧率,得到角速度

$$\omega(t) = \frac{\alpha(t) - \alpha(t-1)}{\Delta t} \quad (9)$$

式中 Δt ——相邻两帧之间的时间间隔

该特征对头部快速摆动行为、甩头等异常行为具有较高敏感性。

2.2.2.4 时序特征

考虑到异常行为通常具有一定的时间持续性,单帧特征难以充分表征异常状态,本文在上述特征基础上引入时序滑动窗口(长度为 f),构建时序统计特征。

(1) 时序窗口长度帧数 f

设滑动窗口长度为 f ,对每一帧 t ,统计区间 $[t-f+1, t]$ 内的特征变化。

(2) 角度摆幅 $A_f(t)$

角度摆幅定义为窗口内头部旋转角的最大变化范围

$$A_f(t) = \max(\alpha) - \min(\alpha) \quad (10)$$

式中 $\max(\alpha)$ ——头部旋转角度的最大值, ($^\circ$)

$\min(\alpha)$ ——头部旋转角度的最小值, ($^\circ$)

该特征用于量化头部旋转幅度,反映摇头行为强度。

(3) 位移幅度 $L_f(t)$

位移幅度用于刻画头部运动范围,定义为窗口内头部参考点位移的最大变化

$$L_f(t) = \max(P) - \min(P) \quad (11)$$

该特征可用于区分轻微姿态调整与持续性抬头、低头行为。

(4) 活动度能量 $E_{v_f}(t)$

在滑动窗口内,定义归一化速度平方和作为活动度能量

$$E_{v_f}(t) = \sum_{i=t-f+1}^t v^2(i) \quad (12)$$

该特征综合反映头部在一段时间内的整体活动水平,用于判别剧烈运动与长时间静止。

2.2.2.5 行为特征输出形式

将上述静态姿态特征、动态姿态特征及时序统计特征统一组织为一维时间序列信号,作为后续异常行为判别规则与事件提取算法的输入。

2.2.3 构建异常行为的规则函数

规则函数以静态姿态特征、动态姿态特征及时序统计特征为输入,仅完成帧级触发判别,而异常行为的持续时间约束、相邻片段合并以及规则冲突消解在后续事件提取模块中统一完成。设第 j 条规则在时刻 t 的输出 R_j 为

$$R_j(t) \in \{0, 1\} \quad (13)$$

当第 j 条规则在时刻 t 被触发时, $R_j(t) = 1$, 否则 $R_j(t) = 0$ 。

行为特征与规则函数的映射关系如图 5 所示。考虑到挤奶场景中异常行为的作用对象不同,将规则函数划分为单牛头部异常行为规则、牛间交互异常行为规则和低优先级补充规则 3 类。其中,单牛头部异常行为规则记为 R_{1n} ,主要用于识别头部快速摆动行为、头部快速上抬行为、头部侧向摩擦行为和卷舌等行为;牛间交互异常行为规则记为 R_{2n} ,主要用于识别近距离互蹭和短时间冲撞等行为;低优先级补充规则记为 R_{3n} ,用于标记未被显式定义但整体活动强度明显异常的行为片段。

本文采用特征阈值组合判别的方式构建各类规则。规则函数与异常行为之间的对应关系以及规则




图5 行为特征与规则函数的映射关系
Fig.5 Mapping relationship between behavioral characteristics and rule functions

函数的具体参数配置如表 1 所示。为避免规则含义交叉,其中显式定义的单牛异常规则和交互异常规则优先于低优先级补充规则。

2.2.4 异常事件提取与统计

规则函数输出的是帧级异常判别结果,但异常行为通常具有一定持续时间,若直接采用逐帧结果作为最终输出,容易受到关键点抖动、局部遮挡和瞬时误检的影响。本方法采用事件级输出奶牛异常行为,将连续的异常帧整合为具有明确起止时间的异常事件,以适应异常行为在短时间内间歇出现的情况。再按照事件优先级输出优先级最高的异常事件,确保最终输出的异常事件具有清晰且唯一的行为语义,事件提取的流程如图 6 所示,参数配置表如表 2 所示。

最终输出结构化的异常事件列表,包括异常类型、所属牛只、起止时间、持续时间及发生次数等信息,为后续异常行为统计分析与结果可视化提供数据支撑。

表 1 规则函数参数配置
Tab.1 Rule function parameter configuration

规则函数	对应行为	输入特征	阈值	判别条件	帧级触发逻辑
R_{11}	头部快速摆动行为	角速度 $\omega(t)$	$\omega_T = 90(^{\circ})/s$	$\omega(t) > \omega_T$	头部转动速度明显增大,鼻方向角在短时窗口内连续偏转,且角度摆幅超过预设范围
		鼻方向角 $\phi(t)$	$\phi_{T1} = 15^{\circ}$	$\phi(t) > \phi_{T1}$	
		角度摆幅 $A_f(t)$	$A_{fT} = 24^{\circ}$	$A_f(t) > A_{fT}$	
R_{12}	头部快速上抬行为	位移幅度 $L_f(t)$	$L_{fT1} = 42$ 像素	$L_f(t) > L_{fT1}$	头部中心位移幅度与运动速度在短时内同步升高,并表现出明显上抬趋势
R_{13}	头部侧向摩擦行为	鼻方向角 $\phi(t)$	$\phi_{T2} = 28^{\circ}$	$\phi(t) > \phi_{T2}$	鼻方向角持续向侧方偏移,且头部位移幅度达到预设条件
		位移幅度 $L_f(t)$	$L_{fT2} = 37$ 像素	$L_f(t) > L_{fT2}$	
R_{14}	卷舌行为	眼鼻距离特征 $E_N(t)$	$E_{NT} = 58$ 像素	$E_N(t) < E_{NT}$	眼鼻相对距离持续异常,表现出与常规头部姿态不一致的局部面部形变特征
R_{21}	近距离互蹭	头参考点 $P(t)$	$P_{T1} = 99$ 像素	$P_1(t) - P_2(t) < P_T$	相邻奶牛头部参考点之间距离持续减小并保持近距离接触,且双方运动强度处于低至中等水平
		线速度 $v(t)$	$V_{T2} = 106$ 像素/s	$v(t) < V_{T2}$	
R_{22}	短时间冲撞	头参考点 $P(t)$	$P_{T2} = 115$ 像素	$P_1(t) - P_2(t) < P_T$	相邻奶牛头部参考点之间距离在短时内快速接近,且至少一方运动速度显著升高
		线速度 $v(t)$	$V_{T3} = 106$ 像素/s	$v(t) > V_{T3}$	
R_{31}	高活动度潜在异常	活动度能量 $E_{vf}(t)$	$E_{vJT}(t) = 1\ 600$	$E_{vf}(t) > E_{vJT}(t)$	头部整体活动度能量和位移幅度在短时间内同时显著增大,但又不满足上述显式规则
		位移幅度 $L_f(t)$	$L_{fT3} = 80$ 像素	$L_f(t) > L_{fT3}(t)$	

3 实验与结果分析

3.1 奶牛面部关键点检测

本文采用基于 DeepLabCut 的关键点感知模块,对鱼骨式挤奶厅视频中的奶牛面部关键点进行检测,并从定位精度、检测完整性及工程适用性等方面对检测结果进行分析。

在模型训练阶段,采用 DeepLabCut 自带的评估工具对网络回归精度进行分析。测试结果表明,在测试集上关键点预测的平均像素误差为 2.48 像素;在置信度阈值 $p = 0.6$ 条件下,测试误

差为 2.44 像素,说明所训练模型具有较好的关键点定位精度,能够满足后续行为分析对关键点精度的需求。

奶牛面部关键点检测结果的可视化示例如图 7 所示。图中采用不同颜色分别标记奶牛的左眼、右眼及鼻尖关键点,并通过连线方式构建简化的面部骨架。

依据第 2.1.2 节所述评价指标,对关键点检测结果进行统计分析。DeepLabCut 模型在 3 类面部关键点上的精确率、召回率、平均精度均值和标准化平均误差分别达到 98.69%、98.61%、97.22% 和




图 6 异常事件提取与统计

Fig. 6 Abomaly detection and statistics

表 2 事件提取参数配置

Tab. 2 Event parameter configuration

参数项	参数含意	阈值
T_n	杂帧过滤阈值	3 帧
T_m	同类事件合并间隔	15 帧
T_{R11}	头部快速摆动行为最小持续时间	5 帧
T_{R12}	头部快速上抬行为最小持续时间	5 帧
T_{R13}	头部侧向摩擦行为最小持续时间	15 帧
T_{R14}	卷舌行为最小持续时间	30 帧
T_{R21}	近距离互蹭最小持续时间	60 帧
T_{R22}	短时间冲撞最小持续时间	10 帧
T_{R31}	潜在异常最小持续时间	1 帧

5.31%,表明该模型在复杂挤奶场景下具有较好的关键点检出能力和定位精度,能够为后续关键点轨迹分析与异常行为检测提供可靠输入。模型在 CPU 条件下单帧推理时间为 370 ms,参数数量为 2.5×10^8 ,

表明该模型在 CPU 条件下可实现稳定推理,满足离线分析与准实时预警需求;若采用 GPU 部署,可进一步提升处理效率。

DeepLabCut 在动物姿态与关键点检测领域已被广泛验证,其基于迁移学习的小样本训练能力和较高精度特性与本文数据规模和工程应用需求较为契合。本文将 DeepLabCut 作为通用关键点感知模块使用,研究重点不在于关键点检测网络本身的结构改进,而在于面向鱼骨式挤奶厅场景的轨迹修正与事件级异常检测流程构建。

为进一步验证关键点感知模块在复杂场景下的检测稳定性,本文在常规测试集之外额外构建了 100 帧独立复杂场景测试集,并按正常清晰、存在遮挡、快速运动、牛间接触和弱光模糊 5 类场景进行分组统计,结果如表 3 所示。总体上,模型在独立复杂场景测试集上的精确率、召回率、平均精度均值和标准化平均误差分别达到 97.78%、97.23%、95.78% 和 6.35%,说明该关键点感知模块在复杂挤奶场景下仍具有较好的关键点检出能力和定位精度。分场景结果表明,正常清晰场景下模型性能最优;在遮挡、快速运动、牛间接触及弱光模糊等复杂条件下,检测性能出现一定下降,其中弱光模糊场景下误差相对较高,但总体仍能够满足后续异常行为分析对关键点轨迹输入的需求。

3.2 基于栏位位置和牛脸朝向双约束融合的多奶牛关键点轨迹修正方法

3.2.1 多奶牛关键点身份跳变问题分析

在鱼骨式挤奶厅场景下,基于 DeepLabCut 获得的多奶牛关键点轨迹在时间维度上常出现身份跳变



图 7 关键点检测结果

Fig. 7 Key point detection results

表 3 复杂场景下的关键点检测结果

Tab.3 Key point detection results in complex scenes

场景类别	场景说明	帧数	精确率/%	召回率/%	平均精度均值/%	标准化平均误差/%
正常清晰	头部清晰可见无遮挡	20	98.93	99.06	97.88	4.67
存在遮挡	关键点存在遮挡	20	97.88	97.12	95.71	6.37
快速运动	头部快速运动	20	97.61	96.95	95.39	6.64
牛间接触	牛间近距离接触	20	97.44	96.71	95.12	6.89
弱光模糊	光照不足或成像模糊	20	97.06	96.33	94.82	7.18

现象,即同一头奶牛在连续帧中的编号发生频繁切换,导致轨迹不连续。该问题在多目标外观相似且空间分布密集的场景中尤为突出,需引入额外的约束对关键点轨迹进行修正。

3.2.2 基于栏位位置约束和牛脸朝向约束的修正方法

结合挤奶厅空间结构特征与奶牛行为特性,引入栏位位置约束和牛脸朝向约束 2 个约束条件,对关键点轨迹进行后处理修正,整体思路如图 8 所示。




图 8 多奶牛关键点轨迹修正流程图

Fig.8 Method for correcting key point trajectories of multiple cows

在鱼骨式挤奶厅中,奶牛头部沿栏位呈顺序排列,各栏位在空间中具有固定的位置关系。由于奶牛在挤奶过程中整体位置变化较小,其头部关键点通常分布在所属栏位附近,因此可利用栏位中心位置作为空间参考,对关键点进行初步身份判别。

设第 i 个检测目标在第 t 帧的空间位置为 c_i^t ,第 k 个栏位中心位置为 L_k ,则基于空间邻近关系的匹配度 D_{stall} 可表示为

$$D_{stall}(i,k) = \| c_i^t - L_k \| \tag{14}$$

该约束反映了奶牛头部位置与栏位之间的对应关系,在大多数正常挤奶状态下能够实现稳定的身份分配。然而在实际挤奶过程中,奶牛常伴随出现偏头、歪头或向相邻栏位伸头等社交行为,如图 9 所

示,此时关键点的空间位置可能偏离原有栏位区域,导致基于栏位位置的约束产生误判。



图 9 奶牛社交行为示意图

Fig.9 Diagram of cattle social behavior

为提高方法在此类复杂场景下的鲁棒性,本文进一步引入牛脸朝向约束作为补充判别依据。如图 10 所示,奶牛在各自栏位中具有相对稳定的朝向模式,因此可以利用关键点所反映的朝向信息与栏位方向之间的一致性,对候选匹配结果进行约束。其一致性关系度 D_{ori} 可表示为

$$D_{ori}(i,k) = 1 - \cos(\theta_i^t - \theta_k) \tag{15}$$

式中 θ_i^t ——检测目标的朝向角

θ_k ——对应栏位的参考方向角




图 10 牛脸朝向约束

Fig.10 Cow face orientation constraint

该约束刻画了目标姿态与场景结构之间的匹配程度,在空间位置发生偏移,栏位位置无法有效约束时,能够提供有效补充信息,以保证奶牛编号不发生跳变。

综上,将栏位位置约束与牛脸朝向约束进行融

合,构建统一的身份判别模型

$$D(i,k) = \alpha D_{\text{stall}}(i,k) + \beta D_{\text{ori}}(i,k) \tag{16}$$

其中 $\alpha + \beta = 1$



图 11 多奶牛关键点轨迹修正前后对比

Fig. 11 Comparison of key point trajectories of multiple cows before and after correction

3.2.3 双约束融合权重确定

为进一步确定栏位位置约束与牛脸朝向约束在融合身份判别模型中的最优权重配置,本文对双约束融合权重系数进行实验分析。本文采用穷举法对权重组合进行搜索,按步长 0.1 共设置 11 组权重,如表 4 所示。

表 4 双约束融合权重确定实验结果

Tab.4 Results of dual-constraint fusion weight determination

α	β	平均编号跳变帧数	准确率/%
1.0	0	3.000	99.00
0.9	0.1	1.875	99.41
0.8	0.2	0.625	99.82
0.7	0.3	0.125	99.96
0.6	0.4	0.375	99.89
0.5	0.5	0.875	99.71
0.4	0.6	1.750	99.38
0.3	0.7	3.125	98.96
0.2	0.8	4.750	98.53
0.1	0.9	5.875	98.04
0	1.0	7.250	97.58

实验以奶牛编号跳变帧数作为评价指标,视频中某一帧中只要有一头奶牛发生编号跳变即把该帧视为编号跳变帧。考虑到挤奶过程具有时间连续性,本文以 10 s 视频片段为基本统计单元,对多段视频进行重复实验,并取平均结果作为最终评价价值。

式中 α, β ——栏位位置与牛脸朝向约束权重系数
多奶牛关键点轨迹修正效果前后对比如图 11 所示。

不同权重组合下的实验结果如表 4 所示。结果表明,当 $\alpha = 0.7, \beta = 0.3$ 时,平均编号跳变帧数最少,准确率最高,综合表现最优。在鱼骨式挤奶厅场景下,栏位位置约束在多奶牛关键点身份修正中起主导作用,牛脸朝向约束则主要对空间位置误判提供补充修正,两者具有较好的互补性。

3.2.4 消融实验

为验证所提出栏位位置约束与牛脸朝向约束在多奶牛关键点轨迹修正中的有效性,本文设计消融实验,对不同约束条件下的身份稳定性进行定量分析,实验评价指标与双约束融合权重确定实验相同。实验共设置 4 种对比方法:仅使用 DLC 原始跟踪无约束修正;仅使用栏位位置约束修正;仅使用牛脸朝向约束修正;栏位位置与牛脸朝向双约束融合修正。实验结果如表 5 所示。

表 5 消融实验结果

Tab.5 Ablation experiment results

栏位位置约束修正	牛脸朝向约束修正	平均编号跳变帧数	准确率/%
-	-	18.500	93.83
√	-	3.000	99.00
-	√	7.250	97.58
√	√	0.125	99.96

注:“√”表示使用该约束,“-”表示不使用该约束,双约束融合修正时权重系数取 $\alpha = 0.7, \beta = 0.3$ 。

在无约束条件下,多奶牛关键点轨迹存在明显编号跳变,平均每 10 s 发生 18.500 次跳变,准确率为 93.83%。加入栏位位置约束后,平均编号跳变帧数降至 3.000,准确率提高至 99.00%;仅采用牛脸朝向约束时,平均编号跳变帧数为 7.250,准确率为 97.58%。当进一步融合栏位位置约束与牛脸朝向约束后,平均编号跳变帧数降至 0.125,准确率提高至 99.96%。修正效果最优,也进一步说明 2 类

约束具有互补性。

3.3 奶牛异常行为检测

基于奶牛面部关键点轨迹的异常行为检测方法检测效果如图 12 所示。当视频数据中奶牛发生异常行为时,方法会在视频画面中对应编号下方标注该异常行为所满足的最高优先级的规则函数名称,同时自动生成该视频内所有异常行为的统计汇总文档。



图 12 异常行为检测方法检测效果

Fig. 12 Detection performance of anomaly detection methods

以人工标注的异常事件作为参考真值,对方法检测结果进行事件级对比分析。分别统计各类异常行为的人工标注事件总数、方法检出事件数、方法漏检事件数、方法误报事件数、事件级精确率、事件级召回率、事件级漏检率和事件级误检率^[25]。

方法检出事件指方法检测结果在时间维度上与人工标注异常事件存在重叠的情况;方法漏检事件指人工标注存在但方法未能检测到的异常事件;方法误报事件则指方法检测到但人工标注中不存在对应异常的事件。方法检测结果如表 6 所示,在单牛异常行为检测方面,人工标记 29 个异常事件,方法输出事件 29 个,正确匹配事件 28 个,仅出现 1 个漏

检事件和 1 个误检事件,事件级的精确率、召回率、漏检率和误检率分别为 96.55%、96.55%、3.45%和 3.45%;在多牛交互异常行为检测方面,人工标记事件总数 12 个,方法输出事件 14 个,正确匹配事件 12 个,出现 2 个误检事件,未出现漏检情况,事件级的精确率、召回率、漏检率和误检率分别为 85.71%、100%、0 和 14.29%。由实验结果可知,本文提出的奶牛异常行为检测方法在合理设置规则阈值参数的条件下,能够检测到大多数人工标注的异常事件,检测结果与人工观察具有较好一致性,说明基于少量关键点和规则驱动的方法能够在不依赖大量行为样本的前提下实现具有工程意义的异常预警。

表 6 奶牛异常行为检测结果								
Tab. 6 Evaluation of methods for detecting abnormal behavior in dairy cows								
规则函数	人工标记异常事件总数/个	方法输出事件/个	漏检事件/个	误检事件/个	事件级精确率/%	事件级召回率/%	事件级漏检率/%	事件级误检率/%
R_{1n}	29	29	1	1	96.55	96.55	3.45	3.45
R_{2n}	12	14	0	2	85.71	100	0	14.29

4 讨论

4.1 异常行为的定义与标注

本文所涉及的异常行为类型是与具有长期一线

经验的牧场技术人员与相关领域专家共同讨论确定,是基于挤奶生产管理的实际需求并非主观设定。异常行为的判定标准主要参考奶牛在挤奶过程中常见的应激反应、设备干扰行为以及可能影

响挤奶安全性和生产效率的异常动作模式,具有明确的工程背景和实践依据。在标注过程中,专家主要依据视频中可观测到的头部姿态变化、运动幅度及持续时间,对异常行为进行事件级标注,而非逐帧精确标注。这种标注方式更符合实际生产管理中关注异常行为的方式,也能够有效避免由于单帧行为边界不清而引入的主观偏差^[26]。本研究检测结果主要服务于挤奶过程异常状态的识别与提示,而非对具体生理或病理原因进行直接诊断。

4.2 面部关键点的选取

本研究选取奶牛面部的左眼中心、右眼中心及鼻尖中心作为关键点,如图 13 所示。左右眼关键点能够较为稳定地反映头部整体位置,而鼻尖关键点对头部朝向及俯仰变化具有较高敏感性,挤奶过程中与异常状态密切相关的行为主要体现在头部姿态和运动变化上,如抬头、低头、转头、甩头及异常接触等。这类行为可通过 3 个关键点构成的几何关系及其时间变化特征有效刻画^[27]。



图 13 面部关键点选取示意图

Fig. 13 Schematic of facial landmark selection

4.3 漏检与误检情况分析

基于关键点轨迹与规则驱动的奶牛异常行为检测方法在挤奶场景中能够实现较为稳定的异常行为识别,但在实际应用中仍存在漏检或误检现象。通过对检测结果进行回溯分析发现,这些问题主要来源于关键点感知受限以及异常行为边界本身的模糊性^[28]。

4.3.1 行为边界模糊性引起的误检与漏检

在挤奶过程中,奶牛会自然产生一定幅度的头部左右摆动、轻微抬头或姿态调整等行为,这些行为在大多数情况下属于正常行为表现。然而,当这些正常行为在幅度、速度或持续时间上与异常行为特征接近时,其行为边界往往难以明确界定^[29]。在此情况下,即使行为专家直接观察视频也难以准确判断该行为是否属于异常蹭擦行为。类似地,当奶牛头部运动速度接近规则函数设定的速度阈值时,其行为往往处于正常与异常之间的过渡区间,由人工标注主观性导致的行为边界模糊使得规则驱动的检测方法在个别样本上不可避免地出现误检或漏检现象。

4.3.2 关键点丢失导致的异常行为漏检

在实际挤奶场景中,奶牛间距离近、头部活动频繁,易产生遮挡,如图 14 所示。当奶牛头部大幅转向或藏于邻牛颈下时,摄像头难以捕捉清晰面部信息,导致左眼、右眼及鼻尖等关键点长时间丢失,无法提取有效时序特征,从而无法判断行为,造成异常漏检。在当前框架下,关键点长时间缺失时方法不作推断,以避免不可靠结果。这是单目视觉与关键点感知条件下难以避免的固有限制^[30]。



图 14 关键点遮挡情况

Fig. 14 Key point occlusion situation

4.4 规则驱动方法的适用性分析

挤奶场景中异常行为发生频率低,异常事件样本数量有限,而正常行为样本占比高,易导致数据驱动模型训练过程中出现类别不平衡问题,难以支撑端到端模型训练。本研究的目标是事件级异常提示,不是大规模通用行为分类,关注的头部快速摆动行为、头部快速上抬行为及牛间接触等异常行为具有较明确的运动学特征,适合通过少量关键点构建可解释规则进行判别,便于工程部署与应用。

5 结论

(1) 本文面向鱼骨式挤奶厅应用场景,开展了基于面部关键点轨迹的奶牛异常行为检测研究。本研究适用于固定摄像机、鱼骨式挤奶厅、奶牛头部正面可见且栏位位置相对稳定的场景;当出现长时间严重遮挡、个体完全脱离栏位空间约束或摄像视角发生明显变化时,关键点连续性与规则适用性可能下降,需结合具体牧场条件进行参数重新标定。在实际挤奶视频数据上对方法的关键模块和整体性能进行了实验验证,研究结果表明该方法在固定视角鱼骨式挤奶厅场景下具有较好的可用性。

(2) 针对鱼骨式挤奶厅的结构特点,设计了栏位空间和牛脸朝向双约束融合轨迹修正策略,以提升个体轨迹连续性与一致性。在双约束权重系数分

别为 $\alpha = 0.7$ 、 $\beta = 0.3$ 时,双约束融合方法在多牛场景下牛只编号切换次数由 18.500 次降至 0.125 次,准确率由 93.83% 提升至 99.96%。消融实验表明,栏位位置约束对身份稳定性提升起主导作用,牛脸朝向约束提供辅助补充,二者融合时轨迹修正效果最优,能够有效提高多奶牛关键点轨迹跟踪的稳定性与可靠性。

(3) 基于面部关键点的奶牛异常行为检测方法能够以事件形式输出奶牛挤奶时的异常行为。实验结果表明,方法检出单牛异常行为事件 29 个,人工标记事件 29 个,其中漏检事件 1 个,误检事件 1 个,事件级的精确率、召回率、漏检率和误检率分别为

96.55%、96.55%、3.45% 和 3.45%;方法检出多牛交互异常行为事件 14 个,人工标记事件 12 个,其中误检事件 2 个,无漏检事件,事件级的精确率、召回率、漏检率和误检率分别为 85.71%、100%、0 和 14.29%。方法整体检测结果与人工标注具有较好一致性,具备工程可用性。

(4) 所采用的 DeepLabCut 关键点感知模块在鱼骨式挤奶厅场景下具有较好的检测精度和稳定性。在测试集上的平均像素误差为 2.48 像素,在置信度阈值为 0.6 条件下误差为 2.44 像素,同时在精确率、召回率、平均精度均值和标准化平均误差分别达到 98.69%、98.61%、97.22 和 5.31%。

参 考 文 献

- [1] Broom D M. Animal welfare: concepts and measurement[J]. Journal of Animal Science, 1991, 69(10): 4167–4175.
- [2] Von Keyserlingk M A G, Rushen J, De Passille A M, et al. Invited review: the welfare of dairy cattle—key concepts and the role of science[J]. Journal of Dairy Science, 2009, 92(9): 4101–4111.
- [3] Weary D M, Niel L, Flower F C, et al. Identifying and preventing pain in animals[J]. Applied Animal Behaviour Science, 2006, 100(1/2): 64–76.
- [4] Martinez G M, Suarez V H, Ghezzi M D. Influence of the human-animal relationship on productivity and animal welfare in dairy farms[J]. Journal of Dairy & Veterinary Sciences, 2019, 11(5): 555825.
- [5] 胡肄农. 智慧奶业关键技术与发展建议[J]. 中国畜牧杂志, 2023, 59(4): 318–322.
- [6] 卢小龙, 崔奎青, 祁昊, 等. 奶牛智慧养殖关键技术研究进展[J]. 黑龙江畜牧兽医, 2025(9): 23–31.
- [7] Ding L Y, Zhang C X, Yue Y X, et al. Wearable sensors-based intelligent sensing and application of animal behaviors: a comprehensive review[J]. Sensors, 2025, 25(14): 4515.
- [8] Trapanese L, Bifulco G, Calanni Macchio A, et al. Precision livestock farming applied to the dairy sector: 50 years of history with a text mining and topic analysis approach[J]. Smart Agricultural Technology, 2025, 10: 100827.
- [9] Yuan L, Li W R, Yue J, et al. A review of cattle behavior recognition methods based on computer vision and deep learning[J]. Smart Agricultural Technology, 2026, 14: 101867.
- [10] 潘浩文, 何梦腾, 邓洪兴, 等. 基于 DCT-YOLO 的轻量化奶牛爬跨行为检测方法[J]. 农业机械学报, 2026, 57(2): 245–255. Pan Haowen, He Mengteng, Deng Hongxing, et al. Lightweight cow mounting behavior detection method based on DCT-YOLO[J]. Transactions of the Chinese Society for Agricultural Machinery, 2026, 57(2): 245–255. (in Chinese)
- [11] Qiao Y L, Truman M, Sukkarieh S. Cattle segmentation and contour extraction based on Mask R-CNN for precision livestock farming[J]. Computers and Electronics in Agriculture, 2019, 165: 104958.
- [12] Wurtz K, Camerlink I, D'Eath R B, et al. Recording behaviour of indoor-housed farm animals automatically using machine vision technology: a systematic review[J]. PLOS ONE, 2019, 14(12): e0226669.
- [13] Long T, Yu R C, You X, et al. FSCA-YOLO: an enhanced YOLO-based model for multi-target dairy cow behavior recognition[J]. Animals, 2025, 15(17): 2631.
- [14] Rao S, Garcia E, Neethirajan S. Video-based cattle behaviour detection for digital twin development in precision dairy systems[J]. npj Veterinary Sciences, 2026, 1(1): 3.
- [15] Wang F, Xia B, Pan L W. Multi-object real-time tracking for intelligent breeding of animal[J]. Computer Science and Information Systems, 2024, 21(4): 1845–1864.
- [16] Mahato S, Bi H Q, Neethirajan S. Dairy DigiD: a keypoint-based deep learning system for classifying dairy cattle by physiological and reproductive status[J]. Frontiers in Artificial Intelligence, 2025, 8: 1545247.
- [17] Taghavi M, Russello H, Ouweltjes W, et al. Cow key point detection in indoor housing conditions with a deep learning model[J]. Journal of Dairy Science, 2024, 107(4): 2374–2389.
- [18] 赵娟娟, 孙新胜, 王超, 等. 规模化奶牛场冬季挤奶厅环境的检测与评价[J]. 中国畜牧杂志, 2019, 55(7): 147–150.
- [19] 蔡骋, 宋肖肖, 何进荣. 基于计算机视觉的牛脸轮廓提取算法及实现[J]. 农业工程学报, 2017, 33(11): 171–177. Cai Cheng, Song Xiaoxiao, He Jinrong. Algorithm and realization for cattle face contour extraction based on computer vision[J]. Transactions of the CSAE, 2017, 33(11): 171–177. (in Chinese)
- [20] 郭虹. 奶牛体型自动评分研究进展及应用建议[J]. 农业技术与装备, 2025(10): 129–130, 133.

[21] 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.

[22] 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.

[23] 董萧,张顺龙,张子睿,等. 基于关键点检测的动态山羊体尺测量[J]. 农业机械学报,2026,57(8):278 – 288.
Dong Xiao, Zhang Shunlong, Zhang Zirui, et al. Dynamic body size measurement of individual goats based on keypoint detection[J]. Transactions of the Chinese Society for Agricultural Machinery, 2026,57(8):278 – 288. (in Chinese)

[24] 熊艳彬,王磊,刘速杰,等. 基于关键点增强的类别级物体 6D 姿态估计研究[J]. 中国科学:技术科学,2026,56(3):721 – 736.
Xiong Yanbin, Wang Lei, Liu Sujie, et al. 6D pose estimation of category-level objects based on keypoint enhancement[J]. Scientia Sinica Technologica, 2026,56(3):721 – 736. (in Chinese)

[25] 黄小平,侯现坤,郭阳阳,等. 基于改进 YOLO v7 – Pose 的牛脸关键点检测与姿态识别方法[J]. 农业机械学报,2024,55(11):84 – 92,102.
Huang Xiaoping, Hou Xiankun, Guo Yangyang, et al. Cow face keypoint detection and pose recognition based on improved YOLO v7 – Pose[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(11):84 – 92,102. (in Chinese)

[26] 孙德洲,刘梦,岳洋,等. 黑龙江省部分地区奶牛肢蹄病发病情况调查与分析[J]. 黑龙江畜牧兽医,2026(3):89 – 96.

[27] 田振江,韩成,张超,等. 基于改进 YOLO v8 关键点检测的西门塔尔牛只个体识别方法[J]. 农业机械学报,2025,56(12):591 – 602.
Tian Zhenjiang, Han Cheng, Zhang Chao, et al. Individual identification method of simmental cattle based on improved YOLO v8 keypoint detection[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025,56(12):591 – 602. (in Chinese)

[28] 严斌,宋懿峰,安晓萍,等. 计算机视觉技术在奶畜生产管理中的应用研究[J]. 中国畜牧杂志,2026,62(3):39 – 48.

[29] 李恩泽,王克俭,司永胜,等. 基于改进 ConvNeXt 的奶牛行为识别方法[J]. 农业机械学报,2024,55(5):282 – 289,404.
Li Enze, Wang Kejian, Si Yongsheng, et al. Cow behavior recognition method based on improved ConvNeXt[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(5):282 – 289,404. (in Chinese)

[30] 宋怀波,华志新,马宝玲,等. 基于 SimCC – ShuffleNetV2 的轻量化奶牛关键点检测方法[J]. 农业机械学报,2023,54(10):275 – 281,363.
Song Huaibo, Hua Zhixin, Ma Baoling, et al. Lightweight keypoint detection method of dairy cow based on SimCC – ShuffleNetV2[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023,54(10):275 – 281,363. (in Chinese)