doi:10.6041/j.issn.1000-1298.2026.06.024

基于深度视觉与类别均衡损失的母猪体况评分方法

周　红[1,2]　刘培杰[1]　谢秋菊[1]　武帅君[1]　王文峰[1]　郑　萍[1]　刘洪贵[3,4]　郑　芳[2,5]

(1. 东北农业大学电气与信息学院, 哈尔滨 150030; 2. 农业农村部智慧养殖技术重点实验室, 武汉 430070;
3. 农业农村部生猪养殖设施工程重点实验室, 哈尔滨 150030; 4. 东北农业大学动物科学技术学院, 哈尔滨 150030;
5. 华中农业大学信息学院, 武汉 430070)

摘要: 母猪体况是评估其生产性能及指导精准饲喂的重要指标。近年来基于机器视觉的体况评分研究受到广泛关注,然而由于目前研究大多依赖二维图像和人为定义的几何特征,二维图像难以反映猪体丰富的三维体型特征,特征表达维度受限。同时,人为定义特征数量和维度有限,难以包含与体况相关的细节特征,造成信息大量的丢失致使评分准确率较低。通过深度视觉技术构建三维点云数据集,提出了基于类别均衡损失函数的 CBLoss - RepSurf (Class-balanced loss function - representative surfaces)母猪体况评分模型,自动提取与体况评分相关的高维特征,实现端到端的母猪体况评分。对57头不同阶段母猪的3 093个点云测试结果表明,CBLoss - RepSurf 模型与不采用类别均衡损失的 RepSurf 模型相比准确率提升1.54个百分点,空怀期、妊娠后期和断奶期母猪的评分准确率分别为94.87%、92.50%和85.50%,与基于体质量和体尺特征的母猪体况评分方法相比分别高6.30、7.00、0.36个百分点,针对不同阶段母猪体况可做到评分更精准,为规模化养殖母猪体况自动评分提供了方法支撑。

关键词: 母猪; 体况评分; 机器视觉; 点云; 类别均衡损失

中图分类号: S24; TP391　**文献标识码:** A　**文章编号:** 1000-1298(2026)06-0258-13　**OSID:**

Sow Body Condition Assessment Based on Deep Vision with Class-balanced Loss

ZHOU Hong[1,2]　LIU Peijie[1]　XIE Qiuju[1]　WU Shuaijun[1]　WANG Wenfeng[1]　ZHENG Ping[1]
LIU Honggui[3,4]　ZHENG Fang[2,5]

(1. *College of Electrical and Information*, *Northeast Agricultural University*, *Harbin* 150030, *China*
2. *Key Laboratory of Smart Farming Technology for Agricultural Animals*, *Ministry of Agriculture and Rural Affairs*, *Wuhan* 430070, *China*
3. *Key Laboratory of Swine Facilities Engineering*, *Ministry of Agriculture and Rural Affairs*, *Harbin* 150030, *China*
4. *College of Animal Science and Technology*, *Northeast Agricultural University*, *Harbin* 150030, *China*
5. *College of Informatics*, *Huazhong Agricultural University*, *Wuhan* 430070, *China*)

Abstract: Sow body condition is an important indicator for evaluating its production performance and guiding accurate feeding. In recent years, machine vision-based body condition scoring has received much attention. However, since most of the current studies rely on two-dimensional images and human-defined geometric features, the two-dimensional images are difficult to reflect the rich three-dimensional body features of the pig body, so the dimension of feature extraction is limited. At the same time, the limited number and dimension of human-defined features make it difficult to include detailed features related to the body condition, resulting in a large amount of information loss leading to a low scoring accuracy. A 3D point cloud dataset was constructed by deep vision technology, and a class-balanced loss function - representative surfaces (CBLoss - RepSurf) sow body condition scoring model was proposed based on the class-balanced loss function, which automatically extracted high-dimensional features related to body condition scoring, and realized end-to-end sow body condition scoring. The end-to-end sow body condition scoring was realized by automatically extracting high-dimensional features related to body

收稿日期: 2024-12-13　修回日期: 2025-02-12

基金项目: 黑龙江省自然科学基金联合基金培育项目(PL2025C017)、黑龙江省教育厅新一轮黑龙江省"双一流"学科协同创新成果孵化项目(LJGXCG2024-F14、LJGXCG2023-062)和农业农村部智慧养殖技术重点实验室开放课题基金项目(KLSFTAA-KF002-2025)

作者简介: 周红(1986—),女,讲师,博士,主要从事畜禽智慧养殖技术研究,E-mail: zh_hlj@126.com

通信作者: 谢秋菊(1976—),女,教授,博士生导师,主要从事畜舍环境控制及智慧养殖技术研究,E-mail: xqj197610@163.com

condition scoring. Tested with 3 093 point clouds of 57 sows at different stages, the results showed that the accuracy of the CBLoss - RepSurf model was improved by 1.54 percentage points compared with the RepSurf model without class-balanced loss, and the scoring accuracies of sows at empty, late gestation, and weaning stages were 94.87%, 92.50%, and 85.50%, respectively, which was comparable to that of the sows scored based on the features of body mass and body size. Compared with the body mass and body size characteristics of the sow body condition scoring method, the accuracy was 6.30 percentage points, 7.00 percentage points and 0.36 percentage points higher, which can achieve more accurate scoring for different stages of sow body condition and provide feasible method support for the automatic scoring of sow body condition in large-scale aquaculture.

Key words: sow; body condition score; machine vision; point cloud; class-balanced loss

0　引言

体况评分是一种评估动物身体状况的量化方法,有助于了解动物的健康状态,指导饲养管理,并预测动物的生产性能[1]。在畜牧业中,人工方式是依赖专业人员观察和触摸动物身体的特定部位,如尾根、后躯和腰躯的皮下脂肪蓄积量,进行直观评分[2]。然而,这种评分方式耗时费力,易引起动物应激反应,同时不利于生物安全管理[3]。近年来,机器视觉技术在动物体型评估方面以其直观、快速等优势受到养殖行业及研究领域的广泛关注,已取得一定进展[4-7]。

利用机器视觉技术实现牛只体况评分研究主要聚焦于二维(Two-dimensional,2D)图像[8-10]和三维(Three-dimensional,3D)图像[11-13],3D 图像包含深度图像和点云。早期评分方法通过人为定义奶牛体型特征,再利用机器学习算法构建这些特征与体况评分之间的关联模型[14-15]。3D 图像在反映奶牛身体状况方面具有更高的精确度。近年来,随着传感器技术和深度学习技术迅猛发展,基于 3D 图像[16-17]建立深度学习模型自动学习体况关键特征,实现了更加精准的体况评分。SHI 等[18]通过捕获奶牛目标区域的深度图像,并转换为点云作为输入数据,构建了融合注意力机制的点云深度学习评分模型,在 0.5 偏差范围内准确率达 96%。

母猪体况评分有基于母猪臀部视图[19]和基于背膘厚度及母猪体型[20]2 种标准,均采用五级评分制。有学者通过获取母猪臀部视图的二维 RGB 图像,提取臀部轮廓后,通过人为定义的长宽比和构象比,建立和体况评分之间的映射[21]。也有研究者基于母猪臀部后视图 RGB 图像,通过改进的 YOLOX (You only look once extended)网络自动提取二维图像特征,进行母猪体况自动评分,准确率可达 80.06%[22]。近年来,随着巡检机器人技术的广泛应用[23],通过巡检机器人搭载二维相机,在母猪体后斜上方 45°位置采集母猪臀背部 RGB 图像,通过卷积神经网络自动提取二维图像特征进行评分,准确率为 91.06%[24]。与二维图像相比,三维图像能反应更多猪体信息[25-26]。利用 Kinect 相机获取母猪臀部后视图的深度图像,计算出臀部的高宽比、臀股面积及曲率半径,建立人为定义特征和背膘厚度的机器学习模型,评分准确率达到 91.7%[27]。

然而,目前研究通常依据母猪臀部图像以人工视觉评分为标准,具有一定主观性。同时,2D RGB 图像对猪体特征表达能力受限,深度图像虽能够表达猪体三维信息,但通过人工定义特征的方式,一般根据主观经验定义有限特征,无法全面精准地表达猪体特征,会造成猪体三维信息的丢失,限制评分准确性和泛化能力。

针对上述问题,本文以背膘厚度作为体况评分标准,以猪体背部点云为基础,探索提取点云高维局部特征和全面的三维体型特征的母猪体况评分方法,提升体况评分精度,实现多品种、不同阶段母猪体况精准、客观评分,以提升猪场管理科学性和决策准确性。

1　数据集获取

1.1　数据采集

数据采集自黑龙江省亚布力林业局红树莓母猪育种基地。猪舍为坡屋顶、有窗半封闭式结构,长度为 49.5 m,宽度为 14.5 m,高度为 2.4 m,如图 1 所示。每舍设有 3 排母猪限位栏及产床,能容纳 150 头母猪。单个限位栏(长为 2.14 m、宽为 0.70 m、高为 1.25 m)前端设置有 1 个食槽和 1 个饮水器,每

(a) 猪舍外部　　(b) 猪舍内部

图 1　猪舍实景图

Fig. 1　Actual photos of pig building

个限位栏仅能容纳1头母猪。舍内饲养大白猪、长白猪和二元杂交母猪(长白猪×大白猪)。对不同生产阶段的母猪采用定量饲喂方式,每天饲喂时间为08:00和14:00。

每天08:00—18:00进行数据采集,采集对象为空怀期、妊娠后期(妊娠第108天)和断奶期(分娩第30天)的经产母猪。数据及图像采集过程如图2所示,通过体质量磅秤、卷尺、体尺测量杆、超声背膘测量仪、深度相机,分别采集母猪体质量、体尺(包括胸宽CW、臀宽HW、胸高CH、臀高HH和体长BL 5个维度数据)、背膘和母猪背部图像。体质量采集设备为地磅(正锋ZF8003型),量程0~800 kg,精度0.5 kg。体尺采集设备为兽用测量杆和卷尺,测量杆高度测量范围为60~120 cm,宽度测量范围为5~50 cm,精度为0.5 cm。卷尺测量范围为0~200 cm,精度0.1 cm。背膘测量超声背膘仪(格劳威BHU-L型)探测深度为50 mm,读数精度为0.01 mm。背膘测量的点P_2位于母猪最后一根肋骨的外切横截面,距离背中线6.5 cm处,背中线两侧对称取点。

(a) 图像及体质量采集　(b) 体尺采集　(c) 背膘采集

图2　数据采集过程

Fig. 2　Process of data acquisition

图像采集设备为深度相机(Intel© RealSense™ D455型),分辨率设为400像素×240像素,帧率为30 f/s。图像采集时将深度相机固定在限位栏侧面中部,距离地面为高度2.1 m,垂直俯视拍摄猪体背部,采集到的图像为母猪背部RGB图像及深度图像。

共采集空怀期240头、妊娠后期27头、断奶期23头母猪体质量、体尺、背膘厚度及其对应背部图像。经人工筛选后,空怀期、妊娠后期和断奶期图像分别为11 997、2 715、2 316幅。

1.2　数据集划分

1.2.1　点云分割数据集

将采集到的RGB图像和深度图像根据相机内参进行坐标系变换转换为点云。将空怀期、妊娠后期和断奶期3个阶段所有母猪点云构建点云分割数据集。该数据集共包括17 028个点云样本,其中空怀期、妊娠后期和断奶期的点云样本数量分别为11 997、2 715、2 316个。按比例3∶1∶1将全部数据划分为训练集(10 200个点云)、验证集(3 400个点云)和测试集(3 428个点云)。

1.2.2　体况评分数据集

不同阶段母猪外形特征与体况评分之间关系存在差异,因此,对不同阶段母猪分别构建体况评分数据集。点云、体质量、体尺和背膘样本在空怀期、妊娠后期和断奶期数据集划分情况分别如表1~3所示。

表1　空怀期体况评分数据集

Tab. 1　Body condition scoring dataset of non-pregnancy sows

数据集	点云数量	体质量数量	体尺数量	背膘数量
训练集	7 445	144	144	144
验证集	2 330	48	48	48
测试集	2 222	48	48	48

表2　妊娠后期体况评分数据集

Tab. 2　Body condition assessment dataset of late-pregnancy sows

数据集	点云数量	体质量数量	体尺数量	背膘数量
训练集	1 850	19	19	19
验证集	410	4	4	4
测试集	455	5	5	5

表3　断奶期体况评分数据集

Tab. 3　Body condition assessment dataset of weaning sows

数据集	点云数量	体质量数量	体尺数量	背膘数量
训练集	1 500	15	15	15
验证集	400	4	4	4
测试集	416	4	4	4

2　体况评分方法

体况评分基本流程如图3所示,以背膘厚度为基准建立体况评分标准体系,方法1建立基于体质量体尺的体况评分的相关关系,方法2在解析背膘和背部点云之间关系基础上,建立基于背部点云的体况评分方法,开展母猪不同阶段体况评分,对比基于体质量体尺的显性定义特征和点云自动提取的高维特征的体况评分方法性能,确定最优评分方法。

2.1　体况评分标准

依据背膘厚度差异,采用文献[20]提出的五级评分标准,将体况划分为瘦、偏瘦、理想、偏肥和肥5个等级,分别对应1~5分。对样本中3个品种(大白猪、长白猪和二元猪)以及不同阶段(空怀期、妊娠后期和断奶期)的母猪,均按此标准进行体况评分。设母猪点P_2背膘厚度为x,其与体况评分的对应关系如表4所示。

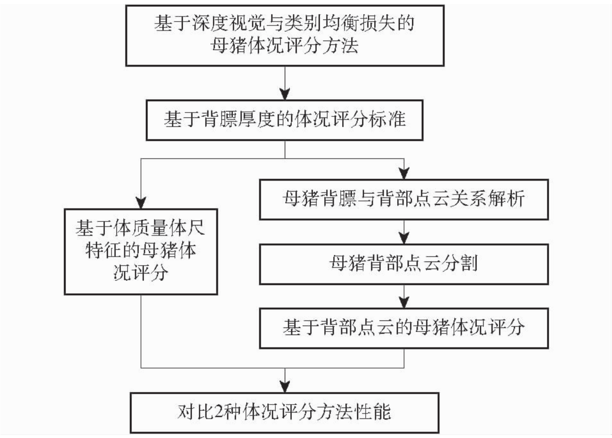

图 3 体况评分基本流程

Fig. 3 Basic flowchart of body condition scoring

表 4 基于背膘厚度体况评分标准

Tab. 4 Body condition score of sows against backfat thickness

体况评分	点 P_2 背膘厚度/mm	体况
1	$x<15.24$	瘦
2	$15.24\leqslant x<17.78$	偏瘦
3	$17.78\leqslant x<20.32$	理想
4	$20.32\leqslant x<22.86$	偏肥
5	$x\geqslant 22.86$	肥

2.2 基于体质量体尺的体况评分

王继英等[28]对大约克猪的体质量、体尺和背膘进行相关性分析发现，背膘和体质量体尺之间存在相关性。以背膘厚度为标准进行体况评分，为探索体质量、体尺和体况评分之间的相关性，以体质量(BW)和体尺(CW、CH、BL、HW、HH)为特征，建立特征和体况评分之间的极致梯度提升树(eXtreme gradient boosting, XGBoost)关系模型[29]，完成不同阶段母猪体况评分。

XGBoost 体况评分模型为分类模型，输入变量为体质量、胸宽、臀宽、体长、胸高及臀高，输出为 1～5 的 5 个体况评分等级。为提升集成能力，XGBoost 模型损失函数计算引入二阶泰勒函数展开。同时在目标函数中加入了正则化项，避免模型过拟合。在最终得到的第 t 棵决策树分裂的目标函数 $\tilde{T}^{(t)}$，每次节点分裂都能使目标函数降低最多，$\tilde{T}^{(t)}$ 计算式为

$$\tilde{T}^{(t)} = -\frac{1}{2}\sum_{j=1}^{T}\frac{G_j^2}{H_j+\lambda}+\gamma T \tag{1}$$

式中 T——当前叶子节点数量

G_j——j 号叶子节点上样本的一阶导数之和

H_j——j 号叶子节点上样本的二阶导数之和

γ、λ——自定义常量

模型将多个回归树进行集成学习，输出端采用 Softmax 分类函数生成体况评分等级。

2.3 母猪背膘与背部点云关系解析

猪体背部点云能够表达与背膘相关的长宽高等体型特征和背部饱满程度等局部特征，因此，基于猪体背部点云，在专注于提升点云局部特征提取能力的 RepSurf 算法[30]的基础上，建立了 RepSurfMSG 背膘预估模型。模型主要包含 3 个步骤：①对猪体点云进行曲面表示。②从曲面表示中提取高维特征。③进行特征降维和聚合输出背膘厚度。

将猪体背部点云以伞形曲面表示，尽量保留猪体点云背部复杂的几何特征。通过逆时针旋转三角形构造出 K 个三角形，形成伞形结构。原始点云中 n 个点位置坐标定义为 x_i，其中 $i=1, 2, \cdots, n$，伞形曲面表示的特征为 u_i，计算公式为

$$u_i = A(\{\Gamma([x'_{ij}, t_{ij}]), j\in\{1,2,\cdots,K\}\}) \tag{2}$$

式中 A——聚合函数

Γ——变换函数

x'_{ij}——根据其质心 x_i 得到的归一化坐标

K——伞形曲面表示中三角形数量

t_{ij}——点 x_i 的伞形曲面中第 j 个三角形曲面特征

将 x_i 与 u_i 连接，作为输入进一步提取特征。定义 1 组输入点 $\{P_1, P_2, \cdots, P_n\}$，其中，$P_i=\{x_i, u_i\}$，$i=1, 2, \cdots, n$。这样，输入特征中包含局部点云位置坐标和几何结构。用 f 表示提取高维特征，计算式为

$$f(P_1, P_2, \cdots, P_n) = \varphi(\mathrm{MAX}\{h(P_i)\}) \quad (i=1,2,\cdots,n) \tag{3}$$

式中 P_i——输入点

φ、h——特征提取网络组成

MAX——最大池化函数

最后，通过全连接层对特征进行逐层降维，输出值为模型的背膘预估值。

2.4 基于母猪背部点云的体况评分

基于背部点云的母猪体况评分建立在点云与母猪背膘 RepSurfMSG 关系模型的原理之上。首先通过 KP-FCNN(Kernel point fully convolutional neural network)点云分割模型提取出猪体点云；再以分割后的母猪背部点云为输入，通过建立端到端的 CBLoss-RepSurf(Class-balanced loss function-representative surfaces)母猪体况评分模型自动提取特征，完成不同阶段母猪体况评分。

2.4.1 母猪背部点云分割

2.4.1.1 点云标注

采集到的点云由猪体和背景 2 部分组成。为消除头部和尾部干扰，将去除头部和尾部的猪体部分

作为分割的目标。头部划分的特征点位于颈部与肩部连接处曲率变化最大处,尾部特征点选取在猪臀尾曲率变化最大处。

2.4.1.2 点云分割模型构建

由于猪体非刚性运动带来的目标点云形态的多样性,以及 KPConv 算法[31]在大规模语义分割问题中突显出的性能优势,基于柔性卷积核 KPConv 算法,建立 KP－FCNN 猪体点云分割模型,完成复杂背景和自由姿态下的猪体点云分割。为提高分割准确性,将颜色信息作为位置信息的辅助特征,应用于猪体点云分割模型的构建。模型总体结构如图 4 所示,包含 3 个主要部分:输入模块、编码解码模块和输出模块。输入模块主要完成对猪体原始点云位置和颜色信息提取,编码解码模块主要完成特征提取和传播,输出模块进行原始点云分类输出。

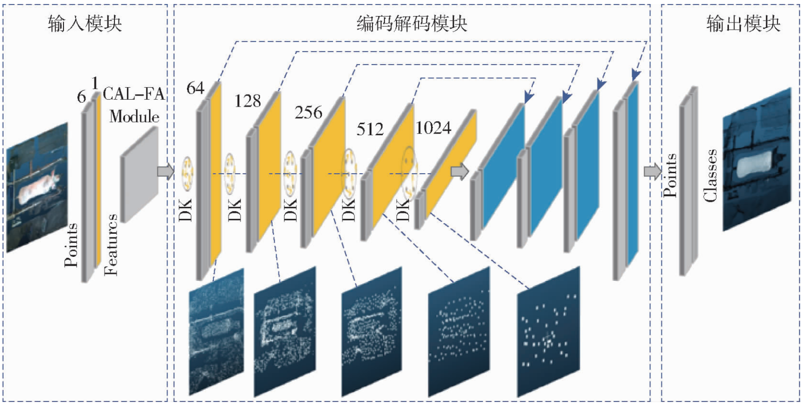

图 4 KP－FCNN 分割模型结构

Fig. 4 Architecture of KP－FCNN segmentation model

输入模块中 CAL－FA(Color and location based feature abstraction module)负责将位置及颜色信息聚合,生成 64 维高维特征,便于进一步编码和解码。设原始点云 P 中,包含 n 个点,记为 $P=\{P_i \mid i=1,2,\cdots,n\}$,点云中的点按照三维坐标分布在三维空间内,任意点 $P_i=(x_i,y_i,z_i,r_i,g_i,b_i)$,$P_i \subset \mathbf{R}^6$,其中,$(x_i,y_i,z_i)$表示位置信息,$(r_i,g_i,b_i)$表示颜色信息。编码解码模块分为特征提取和下采样(前半部分)、特征传播和上采样(后半部分)。特征提取采用 5 层柔性卷积核结构,特征维度从 64 维递增至 1 024 维,点云数量逐渐减少,卷积核半径逐渐扩大。特征传播部分采用 4 层结构,采用层对应传播策略和最近上采样方法获取逐点的特征。输出模块将特征映射到分割标签,通过 Softmax 分类器将点云中的点标记为背景或猪体输出。

2.4.2 母猪体况评分

2.4.2.1 母猪体况评分样本统计

依据背膘划分标准,对空怀期、妊娠后期和断奶期的样本体况评分分布情况进行统计,结果如图 5 所示。在空怀期,母猪体况评分主要集中在 1 和 2,随着评分提高,样本数量明显减少,评分为 5 的母猪数量已非常少,这显示出典型的长尾分布特征。在妊娠后期和断奶期,虽然母猪整体体况有所不同,但评分分布仍呈现长尾特性。

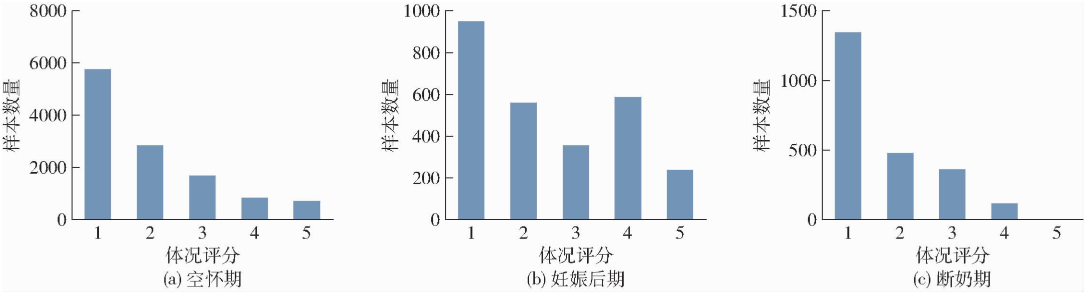

图 5 不同阶段母猪样本体况评分分布

Fig. 5 Distribution of body condition scores of sows at different stages of production

在深度学习模型训练过程中,模型会倾向于关注样本数量多的类别,从而导致对数量少的类别识别性能降低。为应对这种不平衡,并优化模型性能,采用了类别均衡损失函数,在 RepSurfMSG 算法的基础上,构建 CBLoss－RepSurf 母猪体况评分模型。

2.4.2.2 CBLoss－RepSurf 评分模型构建

CBLoss－RepSurf 模型结构如图 6 所示,包含输入模块、特征提取模块和输出模块 3 个部分。

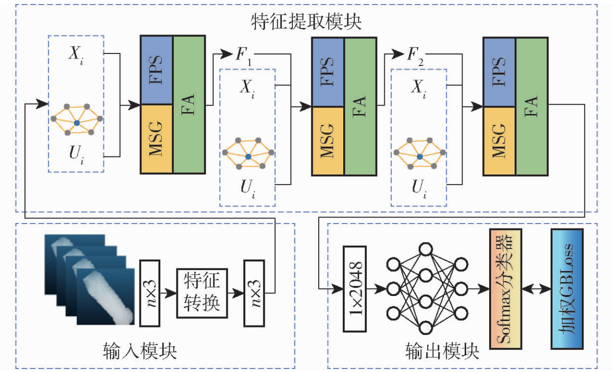

图 6　CBLoss – RepSurf 母猪体况评分模型结构

Fig. 6　Architecture of CBLoss – RepSurf sow body condition scoring model

(1)输入模块

输入模块主要负责点云读取、转换等数据准备工作。初始采样方法设定为随机采样，且采样点数量为 n。将点云位置特征作为初始特征，输入的特征维度为 $n\times3$。随后，通过空间变换，实现不同点云样本间的对齐，变换后点云维度依然为 $n\times3$，将其作为特征提取模块输入。

(2)特征提取模块

特征提取模块负责从输入点云中提取关键特征，是模型的核心部分，包含 3 次采样、分组和特征提取过程。模型采用经典的迭代最远点采样(FPS)策略，并运用了多尺度分组方法(MSG)。在特征提取(FA)时通过多层感知器(MLP)来实现局部特征的聚合。

特征提取模块的输入由点云的坐标值 X_i 与伞形曲面表示的特征 U_i 连接而成。在每次特征提取前，将上一次的输出特征与伞形曲面特征进行连接，作为下一次特征提取模块的输入。在每个特征提取模块中，都融合了上个模块的输出特征 F、点云的原始坐标值 X_i 以及点云的局部伞形几何特征 U_i。

(3) 输出模块

输出模块末端采用 Softmax 分类器，输出 5 个分类的概率值。在模型训练过程中，采用加权 CBLoss 模块对不同类别损失进行差异化加权。由于简单的加权方法或仅基于样本类别频率的倒数进行加权，并不能达到理想效果。因此，CBLoss 采用一种新的加权方法，即根据有效样本数量来确定权重。

由于不同样本之间存在信息重叠，随着样本数量增加，模型从不同样本中提取的边际效益就会减少，基于此原理，提出了有效样本数量的概念。将有效样本数量记为 E_n，计算式为

$$E_n=\frac{1-\beta^n}{1-\beta} \tag{4}$$

式中　n——样本数量

β——超参数，取 0 ~ 1

设 y 为具体类别，由于本文采用 5 级评分，因此 $y\in\{1, 2, 3, 4, 5\}$。p 为模型对不同类别预测的概率，则 $\boldsymbol{p}=(p_1, p_2, p_3, p_4, p_5)^{\mathrm{T}}$，且 $p_y\in[0,1]$。设 $L(\boldsymbol{p},y)$ 为损失函数，则使用有效样本量重新定义的损失函数 $CB(\boldsymbol{p},y)$ 计算式为

$$CB(\boldsymbol{p},y)=\frac{1}{E_{n_y}}L(\boldsymbol{p},y)=\frac{1-\beta}{1-\beta^{n_y}}L(\boldsymbol{p},y) \tag{5}$$

式中　n_y——类别 y 的样本个数

当 $\beta=0$ 时，$E_n=1$，相当于损失函数不加权重。当 $\beta=1$时，$E_n\to n$，相当于有效样本数量趋近于实际样本数量，使用样本类别频率的倒数作为损失值的权重。

使用 Softmax 交叉熵函数作为基本损失函数，CBLoss – RepSurf 母猪体况评分模型的平衡损失函数记作 CBsoftmax($\boldsymbol{p}$, y)，定义为

$$CB_{softmax}(\boldsymbol{p},y)=\frac{1-\beta}{1-\beta^{n_y}}\lg\frac{\exp(p_y)}{\sum_{j=1}^{5}p_j} \tag{6}$$

2.5　参数设置及评价指标

2.5.1　参数设置

XGBoost 体况评分模型采用算法默认参数，学习率为 0.3，树最大深度为 6。

KP – FCNN 模型中 CAL – FA 特征提取模块中输入特征维度 in_features_dim 为 7，柔性卷积核的核点数量为 15。模型训练损失函数使用动量梯度下降优化器最小化逐点的交叉熵损失，设置动量因子为 0.98，批量大小为 8，迭代次数为 70，初始学习率为 0.01。

RepSurfMSG 模型和 CBLoss – RepSurf 模型训练采用批量大小为 8，迭代 100 次，使用 Adam 优化器，学习率设定为 0.001，初始采样点数为 2 500。模型伞形结构包含 8 个分组，采用加和池化(SumPooling)进行特征提取，并返回中心点坐标值(return_polar = TRUE)。CBLoss – RepSurf 模型损失函数设为 CBsoftmax($\boldsymbol{p}$, y)，β 设置为 0.999。

2.5.2　评价指标

点云分割模型和母猪体况评分模型性能采用准确率(Accuracy)、分割精确率(Precision)、召回率(Recall)、F1 分数(F1 score)和平均交并比(Mean intersection over union, mIoU)评估。背膘预估模型采用均方根误差(Root mean square error, RMSE)、平均绝对误差(Mean absolute error, MAE)、均方误差(Total mean square error, MSE)、平均绝对百分比误差(Mean absolute percentage error, MAPE)和决定系数(R^2)作为模型评价指标。

3 结果与分析

3.1 基于体质量体尺的体况评分

3.1.1 不同评分模型测试结果

选用经典的机器学习算法多元线性回归(Multiple linear regression, MLR)、多层感知机(Multilayer perceptron, MLP)、支持向量机(Support vector machine, SVM)和 XGBoost 分别基于体质量和 5 个维度的体尺特征建立母猪体况评分模型,结果如表 5 所示。由表 5 可知,XGBoost 体况评分模型准确率、精确率、召回率和 F1 分数均优于其他模型。

表 5 不同模型空怀期母猪体况评分结果对比

Tab.5 Comparison of body condition scoring results of different models for sows in non-pregnancy %

模型	准确率	精确率	召回率	F1 分数
MLP	50.55	10.11	20.00	13.43
MLR	82.77	74.83	72.77	71.65
SVM	84.44	82.78	76.76	77.45
XGBoost	88.57	87.58	79.73	77.48

XGBoost 体况评分模型通过构建多个决策树并迭代优化,有效降低了模型偏差和方差,提高了泛化能力。同时,XGBoost 引入正则化机制有效防止了过拟合。相比之下,MLP 模型可能因参数众多、训练复杂且易陷入局部最优而表现不佳。MLR 模型虽简单易懂,但处理非线性关系时能力有限。SVM 模型虽在分类上有优势,但面对体质量体尺和体况评分之间的复杂关系时不如 XGBoost 灵活。因此,XGBoost 凭借其强大的集成学习机制和正则化技术,在体况评分任务中取得了最佳效果。

3.1.2 XGBoost 模型在不同阶段评分结果

在空怀期 XGBoost 体况评分最优模型的基础上,使用妊娠后期和断奶期样本进行迁移学习,结果如表 6 所示。由表 6 可知,尽管妊娠后期和断奶期样本量较少,XGBoost 体况评分模型仍展现出良好的适应性。妊娠后期模型各指标同空怀期实验结果基本持平,表明模型在有限样本下泛化能力较强。断奶期模型精确率下降,可能因不同时期体况变化复杂和断奶期样本量较少所致。总体而言,XGBoost 模型通过迁移学习在不同阶段均表现出一定适应性。

表 6 不同阶段母猪体况评分结果对比

Tab.6 Comparision results of XGBoost model at different production stages %

生产阶段	准确率	精确率	召回率	F1 分数
空怀期	88.57	87.58	79.73	77.48
妊娠后期	85.50	83.55	76.82	74.83
断奶期	87.14	66.36	71.04	66.96

3.2 基于母猪背部点云的背膘预估

采用 RepSurfMSG 算法,在空怀期母猪的最优模型基础上进行迁移学习,针对不同阶段的母猪分别建立了基于点云的背膘预估模型,结果如表 7 所示。对比空怀期的测试结果,妊娠后期和断奶期模型的性能相差不大。可见,通过点云能够在一定范围内预测背膘厚度,体况评分等级依据背膘厚度划分,基于此原理提出了基于点云的体况评分方法。

表 7 不同生产阶段 RepSurfMSG 模型背膘预估结果

Tab.7 Backfat estimation results of RepSurfMSG model for different production stages

生产阶段	均方根误差/mm	平均绝对百分比误差/%	平均绝对误差/mm	均方误差/mm^2	决定系数
空怀期	2.37	13.01	1.84	6.38	0.61
妊娠后期	2.12	10.29	1.71	5.13	0.62
断奶期	2.11	14.78	1.65	5.23	0.51

3.3 母猪背部点云分割

3.3.1 不同分割模型测试结果

采用经典点云分割算法 PointNet、PointNet++、PointCNN 建立猪体点云分割模型,同 KP-FCNN 点云分割模型进行性能对比,结果如表 8 所示。其中,KP-FCNN 模型准确率、精确率、召回率、F1 分数和平均交并比分别达到 98.99%、94.70%、93.94%、94.32% 和 94.07%,相较于 PointCNN、PointNet++ 和 PointNet 模型,在各项指标上均表现最优。KP-FCNN 在召回率上的表现较为突出,表明该模型在正确识别前景目标(即猪体)方面具有更好的效果。

表 8 不同分割模型测试结果对比

Tab.8 Comparison results of different segmentation models %

模型	准确率	精确率	召回率	F1 分数	平均交并比
PointNet	97.52	94.44	81.65	87.58	87.60
PointNet++	97.82	94.17	84.80	89.24	89.09
PointCNN	98.05	93.65	89.10	91.32	90.93
KP-FCNN	98.99	94.70	93.94	94.32	94.07

KP-FCNN 采用可变的三维卷积核进行特征提取,这种设计比固定卷积核更能灵活适应不同局部区域的点云特征,从而增强了特征提取能力。此外,KP-FCNN 选择球半径邻域方式选取邻域点,相较其他模型采用的 K 最近邻方法,在面对点云分布不均和含有大量噪声的实际场景中,展现出更强的鲁棒性和适应性。

3.3.2 颜色信息对于分割结果的影响

为探究颜色通道对 KP-FCNN 分割模型性能的影响,分别训练了包含颜色与位置通道的模型,以及仅含位置通道的模型,结果如表 9 所示。

表 9　带颜色通道与不带颜色通道的分割模型测试性能

Tab. 9　Segmentation model test performance with and without color channels　　%

模型	准确率	精确率	召回率	F1 分数	平均交并比
不带颜色通道	98.87	93.94	92.09	93.01	92.86
带颜色通道	98.99	94.70	93.94	94.32	94.07

由表 9 可知，不带颜色通道的模型准确率、精确率、召回率、F1 分数及平均交并比较带颜色通道模型分别低 0.12、0.76、1.85、1.31、1.21 个百分点。由此可见，带颜色通道的 KP－FCNN 分割模型展现出更优的分割性能。

图 7 直观展示了局部分割效果，其中图 7a 为真实标签，图 7b 为带颜色通道的 KP－FCNN 模型分割效果，图 7c 为不带颜色通道的 KP－FCNN 模型分割效果。从总体上看，2 个模型均能较为准确地分割出猪体，主要差异体现在右侧臀部区域。带颜色通道的模型分割效果更接近真实标签。猪体臀部右侧与围栏接近，因深度相机的红外线衍射导致猪臀部的点云与围栏点云相连。由于 RGB 图像未发生畸变，带有 RGB 特征的模型展现出更优的分割效果。因猪体颜色的连续性，使其可作为位置信息的重要辅助特征。

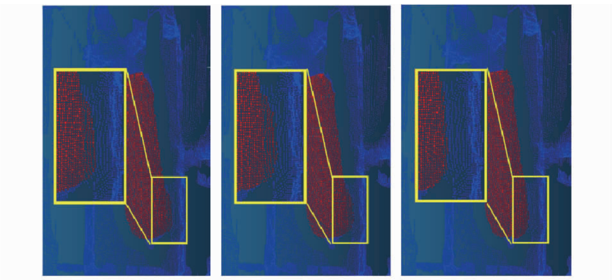

(a) 标记值　(b) 带颜色通道　(c) 不带颜色通道

图 7　带颜色通道和不带颜色通道分割效果

Fig. 7　Segmentation effect with and without color channel

当猪体靠近栏杆或颈部弯曲时，相机红外线衍射产生的噪声点增加了分割难度。因此，对带有颜色通道和不带颜色通道的分割模型分割所得的点云样本进行局部裁剪，裁剪出头颈部和臀部的局部点云，并计算分割准确率，结果如表 10 所示。

表 10　带颜色通道和不带颜色通道模型局部分割准确率

Tab. 10　Local segmentation accuracy for models with and without color channels　　%

模型	头颈部	臀部
不带颜色通道	81.92	83.79
带颜色通道	83.84	86.87

在头颈部的局部分割中，带颜色通道模型的准确率为 83.84%，相较于不带颜色通道模型的 81.92%，提升 1.92 个百分点。在臀部的局部分割中，带颜色通道模型的准确率达到 86.87%，而不带颜色通道模型则为 83.79%，比前者低 3.08 个百分点。由此可见，虽带颜色通道模型在头颈部和臀部的局部分割准确率相较于整体有所降低，但其相较于不带颜色通道模型在头颈和臀部区域的分割性能展现出更高的优势。

3.3.3　分割效果

选取了猪体处于弯曲状态及猪头低下状态等不同姿态测试样本，利用 KP－FCNN 猪体点云分割模型进行分割，再提取猪体前景点云并去除背景点云。可视化效果如图 8 所示，分割后的猪体点云轮廓清晰，准确反映猪体尺寸和背部形态，包括高度变化，即使在特殊姿态下也能稳定表征猪体特征，为母猪体况评分模型提供了精确可靠的输入。猪体在不同姿态下，分割模型均表现优异，展现强鲁棒性。同时，模型能有效捕捉猪体主要结构并去除噪声，省去预处理步骤，提升数据处理效率和准确性。因此，分割后点云能够准确表征猪体特征，同时分割模型具有一定的姿态鲁棒性与去噪能力。

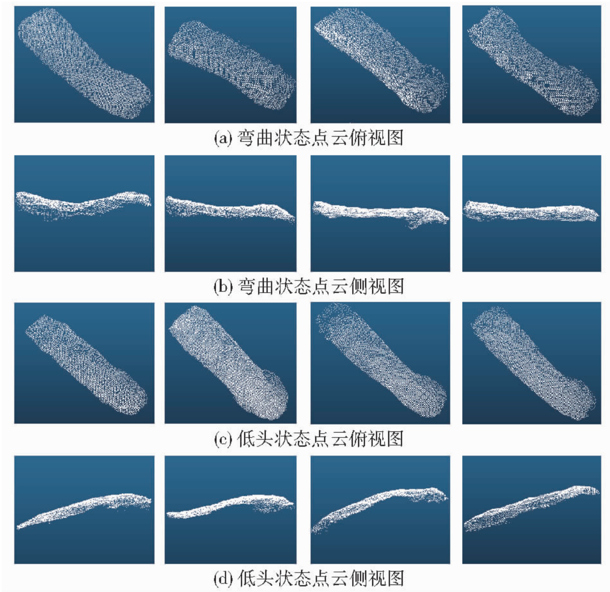

(a) 弯曲状态点云俯视图

(b) 弯曲状态点云侧视图

(c) 低头状态点云俯视图

(d) 低头状态点云侧视图

图 8　分割效果

Fig. 8　Effects after segmentation

3.4　基于点云的体况评分

3.4.1　CBLoss－RepSurf 评分模型测试结果

3.4.1.1　不同模型对比

建立基于经典点云分类算法 PointNet＋＋、DGCNN 和 RepSurf 的母猪体况评分模型，同 CBLoss－RepSurf 母猪体况评分模型进行对比，空怀期母猪测试结果如表 11 所示。CBLoss－RepSurf 模型的分类准确率最高，模型分类性能最优，召回率和 F1 分数在所有模型中最高，但在精确率上，CBLoss－RepSurf 模型低于 Repsurf 模型和 DGCNN 模型。精

表 11　空怀期母猪体况评分模型测试性能对比

Tab. 11　Comparison of test performance of body condition scoring models for sows in non-pregnancy

%

模型	准确率	精确率	召回率	F1 分数
PointNet + +	82. 51	79. 41	74. 06	76. 64
DGCNN	92. 85	92. 81	90. 76	91. 77
RepSurf	93. 03	93. 79	91. 18	92. 46
CBLoss - RepSurf	94. 87	92. 74	93. 93	93. 29

确率与召回率是此消彼长的关系，高的精确率意味着模型在预测为正类时犯错误的几率较低，高的召回率意味着模型能够找出大部分真正的正类样本，漏掉的正类样本较少。体况评分通常用于指导母猪的喂养管理，其主要目的是识别出体况欠佳的母猪。确保不遗漏任何体况不佳的个体显得尤为重要，因此，召回率值越大越好。

为更清晰地评估模型性能，生成 4 个模型测试结果的混淆矩阵，如图 9 所示。CBLoss - RepSurf 模型在划分正确的本类样本时，个数分别为 1 210、461、204、106 和 129，均高于其他模型。假阳性(False positive，FP)值是非本类样本但被模型误判为本类的数量，理论上应越小越好。从混合矩阵纵向看，CBLoss - RepSurf 的 FP 值分别为 34、34、26、7 和 13，总数 114。相比之下，RepSurf 和 DGCNN 的 FP 总数分别为 155 和 159。尽管它们的 FP 值更高，但精确率却更高。原因在于，RepSurf 和 DGCNN 在体况评分为 1 和 2 的分类中 FP 较大，而这 2 类样本占总样本的 48. 16% 和 24. 00%，超过评分为 3、4、5

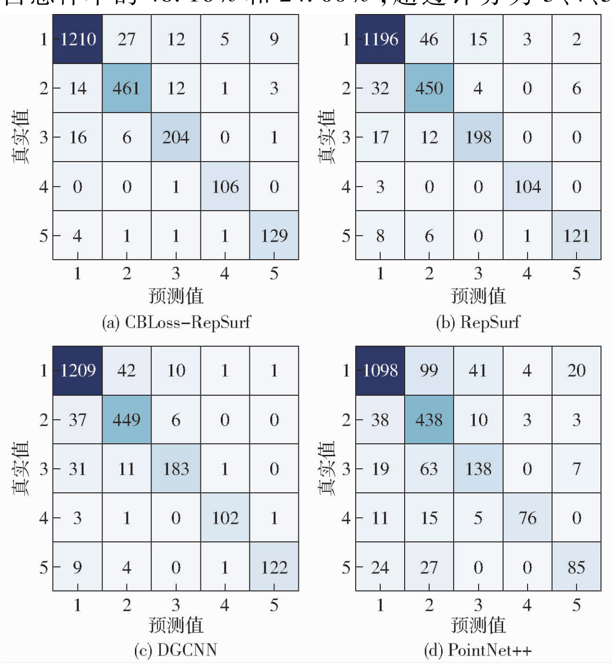

图 9　空怀期母猪不同模型体况评分测试结果混合矩阵

Fig. 9　Confusion matrix of test results of different models on non-pregnancy period sows body condition scoring

的样本总和。因此尽管 FP 大，但真阳性(True positive，TP)也大，对精确率影响小。而 CBLoss - RepSurf 在 1 和 2 分类中 FP 小，在 3、4、5 分类中 FP 大，但这些分类的 TP 占比较小，因此这些 FP 对精确率影响较大，导致值较低。因此，尽管 CBLoss - RepSurf 的精确率较 RepSurf 和 DGCNN 2 个模型更低，但不能说明模型效果更差。从 FP 总数看，CBLoss - RepSurf 明显更优，所以其实际预测结果更佳。

由图 9 可知，CBLoss - RepSurf 模型在对角线以外的错误分类区域数据分布较均匀，而其他模型数据则主要集中在左上角评分为 1 和 2 的 2 类。实际体况数据集中，1 和 2 评分的样本占多数。RepSurf 和 DGCNN 模型预测错误主要集中在这 2 个分类，显示预测偏向样本多的分类。此类模型对 1 和 2 评分的样本预测效果好，但对其他评分样本效果差，鲁棒性不足。相较之下，CBLoss - RepSurf 表现更佳，因引入 CBLoss 类别平衡损失函数，使模型预测不偏向样本多的类别，更好地拟合小样本量分类特征，提升了对各体况评分的鲁棒性和总体性能。

3. 4. 1. 2　不同阶段评分结果分析

在空怀期 CBLoss - RepSurf 体况评分最优模型的基础上，通过迁移学习方法，使用妊娠后期和断奶期的数据集进行了模型训练，结果如表 12 所示。妊娠后期 CBLoss - RepSurf 体况评分模型准确率、精确率、召回率和 F1 分数分别达到 92. 50%、92. 72%、93. 02% 和 92. 86%，同空怀期性能持平。相比之下，断奶期模型的性能相对较差，分别为 85. 50%、76. 18%、88. 67% 和 81. 95%。这可能是由于母猪在断奶期经历了分娩和哺乳，导致背膘损耗较大，体况评分普遍偏低。同时，断奶期的体况数据集中存在严重的样本分布不平衡，体况评分从 1 ~ 5 的样本量占比分别为 58. 27%、20. 87%、15. 65%、5. 21% 和 0%。尽管通过 CBLoss 进行了样本均衡性的调整，但这种不平衡仍对模型效果产生了不利影响。

表 12　不同阶段 CBLoss - RepSurf 模型测试结果

Tab. 12　Test results of CBLoss - RepSurf model at different production stages

%

生产阶段	准确率	精确率	召回率	F1 分数
空怀期	94. 87	92. 74	93. 93	93. 29
妊娠后期	92. 50	92. 72	93. 02	92. 86
断奶期	85. 50	76. 18	88. 67	81. 95

根据测试结果生成了妊娠后期和断奶期 CBLoss - RepSurf 体况评分模型的混淆矩阵，如图 10 所示，清晰地展示了最终测试结果的分布。

总体而言，2 个时期的模型非对角线上的错误

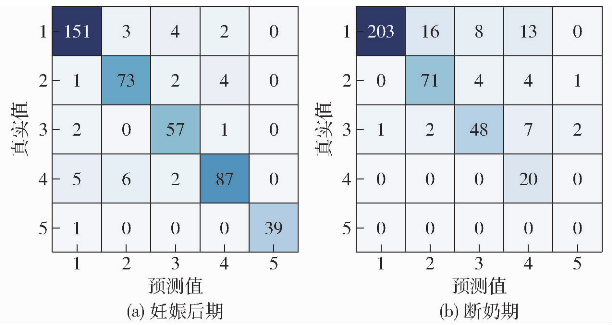

图 10　不同阶段母猪体况评分测试结果混合矩阵

Fig. 10　Confusion matrix of body condition score test results for sows at different stages of production

样本分布相对均匀，这表明模型并未过度拟合到样本量较大的分类上，而是相对均衡地学习了各个体况评分样本的特征。因此，妊娠后期和断奶期的 CBLoss－RepSurf 体况评分模型依然保持了较好的鲁棒性。断奶期的 CBLoss－RepSurf 体况评分模型中，真实评分为 1 的样本被较多地错误分类为评分 2、3、4，具体数量分别为 16、8、13，对最终结果产生了较大影响，这是由于样本数量的不均衡。

3.4.1.3　基于体质量体尺和基于点云的评分结果

采用 2 种方法进行母猪体况评分：①以显性定义的体质量和体尺作为基础特征，通过 XGBoost 模型进行母猪体况评分。②基于点云，通过自动提取高维特征的 CBLoss－RepSurf 模型进母猪体况评分。将 2 种评分方法在不同阶段的结果总结对比，如表 13 所示。

表 13　基于体质量体尺和基于点云的评分结果对比

Tab. 13　Comparison of scoring results based on body weight body size and based on point cloud　　%

生产阶段	特征	准确率	精确率	召回率	F1 分数
空怀期	体质量体尺	88.57	87.58	79.73	77.48
	点云	94.87	92.74	93.93	93.29
妊娠后期	体质量体尺	85.50	83.55	76.82	74.83
	点云	92.50	92.72	93.02	92.86
断奶期	体质量体尺	87.14	66.36	71.04	66.96
	点云	85.50	76.18	88.67	81.95

由表 13 可知，基于点云的方法在准确率、精确率、召回率和 F1 分数上的结果都优于基于体质量体尺的方法。一方面，和人为定义的体质量、胸宽、臀宽、胸高、臀高、体长等一维和二维特征相比，点云不仅能够表明猪体的长宽高等特征，同时能够表征整个猪体背部的复杂三维特征。例如背部的饱满程度、臀部的饱满程度、脊柱的突出曲线等特征和体况评分的相关性较大。因此通过 CBLoss－RepSurf 模型自动提取点云中的高维特征，同人为定义的体质量体尺特征相比，评分准确性更高。另一方面基于点云的 CBLoss－RepSurf 模型迁移学习能力更强。妊娠后期和断奶期的体质量体尺数据量较小，而机器学习模型的迁移学习能力受限，因此在妊娠后期和断奶期的体况评分中，基于点云的深度学习模型表现出了相对优势。

3.4.2　体况评分结果

针对测试集中的空怀期 48 头母猪，妊娠后期 5 头母猪，断奶期 4 头母猪，分别通过基于体质量体尺的 XGBoost 模型和基于点云的 CBLoss－RepSurf 模型进行体况评分，结果如表 14 所示。由表 14 可以看出，基于点云的评分方法与基于背膘的方法对 3 个阶段母猪评分结果相差 3 头，占总数的 5.26%。基于体质量体尺的评分方法与基于背膘的方法相差 8 头，占总数的 14.03%，因此，基于点云的方法与基于背膘的方法最终评分的统计结果相差较小。从不同分数评估结果来看，基于点云的方法和基于背膘的方法评分为 1～5 分的数量差值分别为 1、1、0、0、1 头，分布较为均匀。从母猪不同阶段评分统计结果来看，空怀期相较于其他时期具有更高的准确性，一方面来源于空怀期模型具有更高的精度，另一方面来源于妊娠后期和断奶期的样本量较小，最终评分的统计结果存在一定随机性因素。总体来看，基于点云的母猪体况评分能够大体反映整个猪场生产管理水平与饲喂水平。

表 14　不同阶段评分结果统计

Tab. 14　Statistics on scoring results of different production stages

生产阶段	母猪总数	评分方法	1 分	2 分	3 分	4 分	5 分
空怀期	48	背膘	27	11	5	2	3
		体质量体尺	26	14	4	2	2
		点云	28	10	5	2	3
妊娠后期	5	背膘	1	1	1	1	1
		体质量体尺	2	1	0	1	1
		点云	2	1	1	1	0
断奶期	4	背膘	2	1	1	0	0
		体质量体尺	2	1	1	0	0
		点云	2	1	1	0	0

基于点云的方法评分为 1～5 分的母猪数量分别为 32、12、7、3、3 头，其中体况为 1 分（瘦）和 2 分（偏瘦）的母猪数量较多，可见该实验猪场中的母猪体况评分较低，母猪整体偏瘦，据此可提升整个猪场母猪的饲喂量。

3.4.3　CBLoss－RepSurf 模型特征可视化

为了解 CBLoss－RepSurf 模型学习到了猪体的哪些特征，建立了梯度加权点激活图（Gradient weighted point activation mapping，PAM）[32]，结果如图 11 所示，图中红点表示权重最大且最常被激活的区域，黄、绿点表示整个猪体均为较活跃的特征区域，蓝点表示最少激活的区域。红点主要集中在猪体的脊柱区域，而脊柱区域是能够表征猪体长宽高等维度特征的重要区域，CBLoss - RepSurf 模型成功捕捉到脊柱区域的关键特征。在整体特征图中，黄、绿点广泛分布在猪体的不同部位，由于整个猪体的点云能够全面反映猪体型的各个维度，因此为有效特征。蓝点较为稀疏，主要分布在猪体一侧的边缘区域和噪声点分布的区域。鉴于猪体的对称性，通过学习一侧的特征即可准确获取其长宽高信息，因此忽略另一侧身体边缘特征有助于算法快速集中于关键特征。可见，CBLoss - RepSurf 体况评分模型捕捉到了对生猪体型具有重要影响的关键特征。

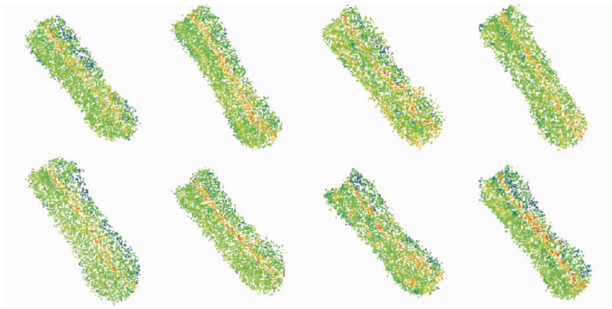

图 11 CBLoss - RepSurf 体况评分模型的 PAM 图

Fig. 11 PAM of CBLoss - RepSur body condition score model

3.4.4 与其他文献方法对比

目前母猪体况评分研究大致分为 2 类，如表 15 所示。一类基于人为定义的长宽高、面积和曲率等特征构建特征和体况评分之间的机器学习模型[21,27]。另一类基于 RGB 图像，通过深度学习模型进行体况评分[22]。

表 15 与其他文献对比结果

Tab. 15 Comparative results with other literature

方法	模型类型	特征提取方式	特征	基础图像	准确率/%
文献[27]	机器学习模型	人工定义	臀部的高宽比、臀股面积及曲率半径	深度图像	91.70
文献[21]	机器学习模型	人工定义	臀部长宽比和构象比	RGB 图像	93.13
文献[22]	深度学习模型	自动提取	隐性高维特征	RGB 图像	80.06
本文	深度学习模型	自动提取	隐性高维特征	点云	94.87

基于人为定义特征的方法，对特征定义的维度受限，很难定义猪体的细节特征。同时，机器学习模型对不同特征的拟合能力受限。通过深度学习模型能够自动的学习到与体况评分相关的隐性的高维度的特征，因此在通过机器视觉进行母猪体况评分方面显示出了更强的适用性。通过 RGB 图像进行体况评分的方法，由于二维图像能够表达的特征维度受限，因此同能够表达猪体复杂体型特征的点云相比，评分准确率较低。

4 结论

（1）体质量、体尺同体况评分之间存在相关性，基于体质量、胸宽、臀宽、体长、胸高、臀高构建的 XGBoost 母猪体况评分模型，空怀期、妊娠后期和断奶期评分准确率分别为 88.57%、85.50% 和 87.14%。

（2）构建的端到端 KP - FCNN 点云分割模型实现了在复杂背景和母猪多种姿态下的点云分割，总体精度达到 98.99%，显著优于其他经典点云分割模型。引入颜色信息相较于不采用颜色信息，模型精度提高 0.12 个百分点，同时对头颈部和臀部进行局部统计的结果显示，颜色信息在此局部区域对准确率的影响更大。

（3）针对体况评分样本的长尾分布问题，提出的基于母猪背部点云与类别均衡损失的 CBLoss - RepSurf 体况评分模型，实现了基于深度视觉的母猪体况自动评分。同基于体质量体尺的体况评分方法相比，基于点云的评分方法性能更优。与不采用类别均衡损失的模型相比，准确率提升 1.54 个百分点。空怀期、妊娠后期和断奶期体况评分准确率分别达到 94.87%、92.50% 和 85.50%。

（4）基于三维点云的体况评分方法与基于背膘的方法最终评分相差 5.26%，同时，对不同分数评分水平差异较小，对大白猪、长白猪、二元猪等不同品种，空怀期、妊娠后期和断奶期不同阶段母猪具有适用性。评分结果能够反映出母猪的总体体况分布水平，为规模化养殖中母猪的生产性能评估和精准饲喂提供了有利支持，对提升管理水平和生产效率具有重要意义。

参 考 文 献

[1] 吴宇峰，李一鸣，赵远洋，等. 基于计算机视觉的奶牛体况评分研究综述[J]. 农业机械学报，2021，52(增刊)：268－275.
WU Yufeng, LI Yiming, ZHAO Yuanyang, et al. Review of research on body condition score for dairy cows based on computer

vision[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(Supp.): 268 – 275. (in Chinese)

[2] VIEIRA A, BRANDAO S, MONTEIRO A, et al. Development and validation of a visual body condition scoring system for dairy goats with picture-based training[J]. Journal of Dairy Science, 2015, 98(9): 6597 – 6608.

[3] 刘云玲,魏艳辉,徐小伟,等. 奶牛健康监测设备与技术研究及应用进展综述[J]. 农业机械学报,2023,54(增刊1):303 – 314.
LIU Yunling, WEI Yanhui, XU Xiaowei, et al. Review of research on dairy cow health monitoring equipment, technology and application[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(Supp.1): 303 – 314. (in Chinese)

[4] BAO J, XIE Q. Artificial intelligence in animal farming: a systematic literature review [J]. Journal of Cleaner Production, 2022, 331: 129956.

[5] 滕光辉,冀横溢,庄晏榕,等. 深度学习在猪只饲养过程的应用研究进展[J]. 农业工程学报, 2022,38(14):235 – 249.
TENG Guanghui, JI Hengyi, ZHUANG Yanrong, et al. Research progress of deep learning in the process of pig feeding[J]. Transactions of the CSAE, 2022, 38(14): 235 – 249. (in Chinese)

[6] 陆明洲,光二颖,陈子康,等. 基于双视角图像的山羊体尺自动测量方法[J]. 农业机械学报,2023,54(8):286 – 295.
LU Mingzhou, GUANG Erying, CHEN Zikang, et al. Automatic measurement method of goat body size based on double vision angle camera image[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(8): 286 – 295. (in Chinese)

[7] 何威,米阳,刘刚,等. 基于双流跨模态特征融合模型的群养生猪体质量测定[J]. 农业机械学报,2023,54(增刊1): 275 – 282.
HE Wei, MI Yang, LIU Gang, et al. Estimation of pig weight based on cross-modal feature fusion model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(Supp.1): 275 – 282. (in Chinese)

[8] BERCOVICH A, EDAN Y, ALCHANATIS V, et al. Development of an automatic cow body condition scoring using body shape signature and Fourier descriptors[J]. Journal of Dairy Science, 2013, 96(12): 8047 – 8059.

[9] AZZARO G, CACCAMO M, FERGUSON J D, et al. Objective estimation of body condition score by modeling cow body shape from digital images[J]. Journal of Dairy Science, 2011, 94(4): 2126 – 2137.

[10] 黄小平,冯涛,郭阳阳,等. 基于改进 YOLO v5s 的轻量级奶牛体况评分方法[J]. 农业机械学报,2023,54(6):287 – 296.
HUANG Xiaoping, FENG Tao, GUO Yangyang, et al. Lightweight dairy cow body condition scoring method based on improved YOLO v5s[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(6): 287 – 296. (in Chinese)

[11] SPOLIANSKY R, EDAN Y, PARMET Y, et al. Development of automatic body condition scoring using a low-cost 3-dimensional Kinect camera[J]. Journal of Dairy Science, 2016, 99(9): 7714 – 7725.

[12] FISCHER A, LUGINBÜHL T, DELATTRE L, et al. Rear shape in 3 dimensions summarized by principal component analysis is a good predictor of body condition score in Holstein dairy cows[J]. Journal of Dairy Science, 2015, 98(7): 4465 – 4476.

[13] 赵凯旋,刘晓航,姬江涛. 基于 EfficientNet 与点云凸包特征的奶牛体况自动评分[J]. 农业机械学报, 2021, 52(5): 192 – 201.
ZHAO Kaixuan, LIU Xiaohang, JI Jiangtao. Automatic body condition scoring method for dairy cows based on EfficientNet and convex hull feature of point cloud[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(5): 192 – 201. (in Chinese)

[14] LIU D, HE D, NORTON T. Automatic estimation of dairy cattle body condition score from depth image using ensemble model [J]. Biosystems Engineering, 2020, 194: 16 – 27.

[15] ZIN T T, SEINT P T, TIN P, et al. Body condition score assessment of depth image using artificial neural network[C]// Proceedings of the 12th International Conference on Computer Modeling and Simulation, 2020: 33 – 37.

[16] YUKUN S, PENGJU H, YUJIE W, et al. Automatic monitoring system for individual dairy cows based on a deep learning framework that provides identification via body parts and estimation of body condition score[J]. Journal of Dairy Science, 2019, 102(11): 10140 – 10151.

[17] RODRÍGUEZ A J, ARROQUI M, MANGUDO P, et al. Body condition estimation on cows from depth images using convolutional neural networks[J]. Computers and Electronics in Agriculture, 2018, 155: 12 – 22.

[18] SHI W, DAI B, SHEN W, et al. Automatic estimation of dairy cow body condition score based on attention-guided 3D point cloud feature extraction[J]. Computers and Electronics in Agriculture, 2023, 206: 107666 – 107674.

[19] JOHNSON C, STALDER K, KARRIKER L. Sow condition scoring guidelines[J]. National Hog Farmer, 2006, 51(4): 7 – 10.

[20] JOHNSTON L. National swine nutrition guide [M]. Des Moines, Iowa, US: Pork Center of Excellence, 2010:108 – 122.

[21] HUANG M H, LIN E C, KUO Y F. Determining the body condition scores of sows using convolutional neural networks[C]// 2019 ASABE Annual International Meeting American Society of Agricultural and Biological Engineers, 2019: 1 – 7.

[22] HE H, CHEN C, ZHANG W, et al. Body condition scoring network based on improved YOLOX[J]. Pattern Analysis and Applications, 2023, 26(3): 1071 – 1087.

[23] 沈明霞,陈金鑫,丁奇安,等. 生猪自动化养殖装备与技术研究进展与展望[J]. 农业机械学报,2022,53(12):1 – 19.
SHEN Mingxia, CHEN Jinxin, DING Qi'an, et al. Current situation and development trend of pig automated farming equipment application[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(12): 1 – 19. (in Chinese)

[24] XUE H, SUN Y, CHEN J, et al. CAT – CBAM – Net: an automatic scoring method for sow body condition based on CNN and transformer[J]. Sensors, 2023, 23(18): 7919 – 7933.

[25] 耿艳利,季燕凯,岳晓东,等. 基于点云语义分割的猪只体尺测量方法研究[J]. 农业机械学报,2023,54(7):332 – 338,380.

GENG Yanli, JI Yankai, YUE Xiaodong, et al. Pigs body size measurement based on point cloud semantic segmentation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(7): 332 - 338,380. (in Chinese)

[26] 沈维政,张哲,戴百生,等. 基于 Cow - DETR 与深度图像的非接触式奶牛体质量评估[J]. 农业机械学报,2023,54(8): 277 - 285,319.
SHEN Weizheng, ZHANG Zhe, DAI Baisheng, et al. Non-contact predicting method of dairy cow weight based on Cow - DETR and deep image[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(8): 277 - 285,319. (in Chinese)

[27] 滕光辉,申志杰,张建龙,等. 基于 Kinect 传感器的无接触式母猪体况评分方法[J]. 农业工程学报, 2018, 34(13): 211 - 217.
TENG Guanghui, SHEN Zhijie, ZHANG Jianlong, et al. Non-contact sow body condition scoring method based on Kinect sensor[J]. Transactions of the CSAE, 2018, 34(13): 211 - 217. (in Chinese)

[28] 王继英,韩丽娟,王诚,等. 大约克体型性状的相关、聚类与主成分分析[J]. 养猪,2019(1): 65 - 67.
WANG Jiying, HAN Lijuan, WANG Cheng, et al. Correlation, clustering and principal component analysis of the body type related traits of Yorkshire[J]. Swine Production,2019(1): 65 - 67. (in Chinese)

[29] CHEN T, GUESTRIN C. XGBoost: a scalable tree boosting system[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2016: 785 - 794.

[30] RAN H, LIU J, WANG C. Surface representation for point clouds[C]//Proceedings of the Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 18942 - 18952.

[31] THOMAS H, QI C R, DESCHAUD J E, et al. Kpconv: flexible and deformable convolution for point clouds[C]//Proceedings of the Proceedings of the IEEE/CVF international Conference on Computer Vision, 2019: 6411 - 6420.

[32] 周红. 基于深度视觉的母猪体况评估方法研究[D]. 大庆:黑龙江八一农垦大学,2024.
ZHOU Hong. Research on the method of sow body condition evaluation based on deep vision[D]. Daqing: Heilongjiang Bayi Agricultural University,2024. (in Chinese)

(上接第 257 页)

[25] 戴海发,卞鸿巍,杜红松,等.基于自适应因子图优化的导航系统信息融合方法[J].中国惯性技术学报,2023,31(1): 45 - 52,60.
DAI Haifa, BIAN Hongwei, DU Hongsong, et al. Navigation system information fusion method based on adaptive factor graph optimization[J]. Journal of Chinese Inertial Technology, 2023, 31(1): 45 - 52, 60. (in Chinese)

[26] 丛佩超,崔利营,万现全,等.基于改进 ORB - SLAM2 的果园喷药机器人定位与稠密建图算法[J].农业机械学报,2023, 54(7):45 - 55.
CONG Peichao, CUI Liying, WAN Xianquan, et al. Localization and dense mapping algorithm for orchard spraying robot based on improved ORB - SLAM2[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(7):45 - 55. (in Chinese)

[27] 杨奇峰, 曲道奎, 徐方. 基于 3D - NDT 的移动机器人定位算法研究[J]. 控制工程, 2020, 27(4): 613 - 619.
YANG Qifeng, QU Daokui, XU Fang. Research on mobile robot positioning algorithm based on 3D - NDT[J]. Control Engineering, 2020, 27(4): 613 - 619. (in Chinese)

[28] XIE B, JIN Y, FAHEEM M, et al. Research progress of autonomous navigation technology for multi-agricultural scenes[J]. Computers and Electronics in Agriculture, 2023, 211: 107963.

[29] DRENJANAC D, TOMIC S, AGUERA J, et al. WiFi and Satellite-based location techniques for intelligent agricultural machinery controlled by a human operator[J]. Sensors, 2014, 14(10): 19767 - 19784.

[30] 刘诚,李金阳,贾娜,等.农林环境下 RTK - UWB 多传感器融合定位方法[J].林业工程学报,2024,9(6):142 - 151.
LIU Cheng, LI Jinyang, JIA Na, et al. Multisensor fusion positioning method for forest and agricultural environments[J]. Journal of Forest Engineering, 2024, 9(6): 142 - 151. (in Chinese)

[31] 喻俊楠,吴学群,赵辉友.基于改进欧式距离聚类中心的 ICP 点云配准方法[J].激光与红外,2024,54(10):1541 - 1546.
YU Junnan, WU Xuequn, ZHAO Huiyou. ICP point cloud registration with enhanced Euclidean distance based cluster centers [J]. Laser & Infrared,2024,54(10):1541 - 1546. (in Chinese)

[32] 许哲,董林啸,吴家跃.改进 ICP 算法的激光雷达点云配准[J].测绘通报,2024(4):1 - 5.
XU Zhe, DONG Linxiao, WU Jiayue. Point cloud registration of LiDAR based on improved ICP algorithm[J]. Bulletin of Surveying and Mapping, 2024(4): 1 - 5. (in Chinese)

[33] XING X, DING H, LIANG Z, et al. Robot path planner based on deep reinforcement learning and the seeker optimization algorithm[J]. Mechatronics, 2022, 88: 102918.

[34] ZHANG J, SALAM M S B H J, YI L, et al. Design and implementation of SLAM technology and navigation technology in smart mobile device based on ROS system[C]//International Conference on Image Processing and Artificial Intelligence, 2024: 929 - 933.