

程灿,冯涛,黄小平,等.轻量级卷积神经网络在奶牛体况评分中的应用[J].华中农业大学学报,2024,43(1):249-257.  
DOI:10.13300/j.cnki.hnlkxb.2024.01.029

## 轻量级卷积神经网络在奶牛体况评分中的应用

程灿<sup>1</sup>,冯涛<sup>1</sup>,黄小平<sup>1</sup>,郭阳阳<sup>1</sup>,梁栋<sup>1</sup>,史道玲<sup>2</sup>

1. 安徽大学互联网学院,合肥 230039; 2. 安徽新华学院电子通信工程学院,合肥 230088

**摘要** 为对奶牛体况信息进行高效地实时监测以便满足商业化的需求,提出一种改进轻量级注意力机制网络模型(Shuffle-ECANet)。首先,针对8 972幅含有奶牛尾部的图像样本,通过专家对奶牛体况进行人工评分,并构建数据集;然后以轻量级ShuffleNet-v2 1×网络为基础,在特征提取过程中引入高效的通道注意力模块,强化网络对奶牛体况特征的提取能力。此外,采用H-Swish激活函数,避免神经元坏死现象;最后通过进一步精简网络结构得到Shuffle-ECANet网络模型。结果显示,Shuffle-ECANet模型针对各类别奶牛的识别准确率为97%以上,且在体况评分(body condition scoring, BCS)误差分别为0、≤0.25和≤0.5的体况评价结果中,Shuffle-ECANet模型均优于EfficientNet-v1、MobileNet-v3、ShuffleNet-v2 1×和ResNet34等模型,证明本研究方法的有效性。

**关键词** 体况评分; ShuffleNet-v2网络; 注意力机制; 智慧养殖; 轻量级; 激活函数

**中图分类号** TP391 **文献标识码** A **文章编号** 1000-2421(2024)01-0249-09

体况评分(body condition scoring, BCS)是以动物身体中体内脂肪含量为依据,用来衡量动物能量代谢状况、健康管理水平的重要方法。合理的体况管理能够有效避免分娩时奶牛跛行和子宫内膜炎的发生,对奶牛产前和产后管理具有非常重要的意义。体况异常和突变是奶牛代谢紊乱的主要表征之一,定期评估奶牛体况是提高奶牛产奶量、繁殖效率、降低疾病发生率的有效途径<sup>[1-3]</sup>。传统的体况评分方法主要是人工评价,评分员根据BCS图表信息<sup>[4]</sup>,通过对奶牛身体区域的观察来进行评分,但存在主观性、评分结果重复性低等缺点<sup>[5]</sup>。此外,体脂测量<sup>[6]</sup>、血脂测量<sup>[7]</sup>以及超声波成像<sup>[8]</sup>等方法也被用于奶牛体况评价,但成本高、耗时且繁琐,不利于实时性检测。在规模化畜牧业发展中,上述方法难以满足养殖的需求,故急需开发一种快速、廉价且精度高的BCS评价方法来评估不同生长阶段的奶牛体况。

近年来,随着深度学习技术的发展,其高效快速的检测能力和强大的特征表征能力满足实时、高效、高精度的实际需求,在精准农业中得到广泛应用<sup>[9-11]</sup>,例如目标检测<sup>[12]</sup>、行为识别<sup>[13]</sup>、体况评价<sup>[14]</sup>、体质量预测等<sup>[15]</sup>。其中奶牛体况评价是热门研究之

一。黄小平<sup>[16]</sup>使用2D相机获取5 470张奶牛的后视图,手动标注奶牛关键身体部位(尾巴、背部、臀部)并构建数据集,采用改进的SSD方法对牛尾图像进行定位和分类,最终BCS在0.5分差范围内的平均准确率为98.46%。赵凯旋等<sup>[17]</sup>采用3D相机来获取奶牛的背部深度图像,结合点云方法进一步获取奶牛背部轮廓三维信息作为深度学习模型的数据集,结果表明深度学习可提高BCS的准确率。Sun等<sup>[18]</sup>使用3D相机获取686头奶牛的背部三维图像,利用超声波技术测量背膘厚度来确定奶牛的BCS并构建样本集,通过训练深度学习网络模型,实现奶牛BCS的自动检测。上述研究表明,深度学习技术应用于奶牛体况评分是可行的且具有较高的应用前景。但在实际生产中,为满足奶牛不同生长阶段营养管理需求,理想BCS值应该与实际BCS值分差不超过0.25,且2D相机比3D相机具有价格低、前期工作准备较少等优势,现有自动评分系统的精度、实用性与实际养殖管理的理想标准仍存在一定差距。

为了提高深度学习技术在体况评分领域的实用性和准确率,本研究提出了一种改进的网络模型Shuffle-ECANet。通过专家对奶牛体况图像进行人

收稿日期:2022-08-11

基金项目:安徽省教育厅自然科学基金项目(KJ2021A0024)

程灿, E-mail: y20301008@stu.ahu.edu.cn

通信作者:梁栋, E-mail: dliang@ahu.edu.cn

工评分构建数据集,然后以轻量级 ShuffleNet-v2  $1\times$  网络为基础,在特征提取过程中加入高效通道注意力模块,强化网络对奶牛体况特征的提取能力,修改激活函数提高了神经元的使用效率,最后对网络结构进行裁剪得到 Shuffle-ECANet 网络模型,以实现自然环境下奶牛体况的精准高效评分,为对奶牛体况信息进行高效地实时监测提供参考。

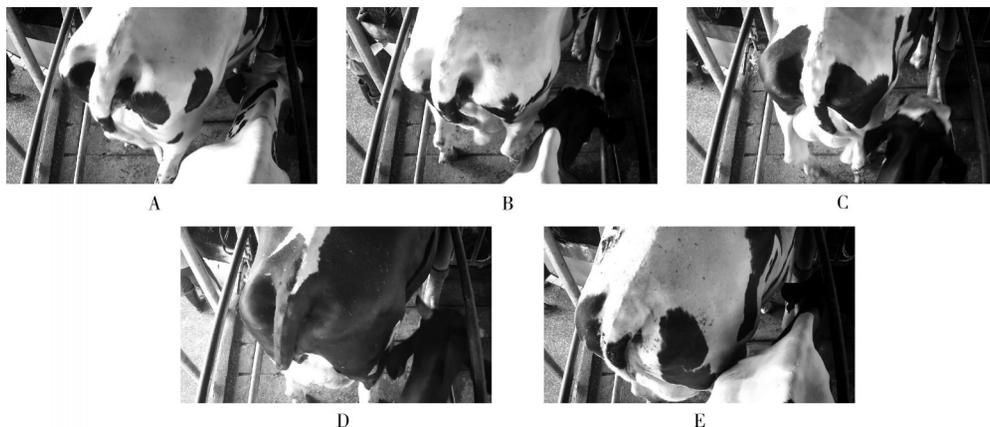
## 1 材料与方法

### 1.1 数据采集

图像采集于安徽省六安市安徽华好生态养殖有限公司,采集平台如图1所示。相机(DS-2CD3T56 DWD-I5,500万像素,海康威视)安装在奶牛挤奶通道上方,距地面2.4 m,垂直向下,以获取奶牛经通道时的俯视视频,并存储在硬盘录像机中。其中,帧频为25帧/s,921 600像素。由于通道宽度有限,保证奶牛按照先后顺序进入,在此条件下能够有效避免奶牛图像关键部位遮挡、干扰等问题,并可采集到与体况评分高度相关的奶牛尾部关键特征信息。



图1 硬件设备  
Fig.1 Hardware devices



A: BCS=3.25; B: BCS=3.50; C: BCS=3.75; D: BCS=4.00; E: BCS=4.25.

图2 图像示例

Fig.2 Image examples

### 1.2 图像预处理

对输入图像进行标准化处理可以避免网络在训

此外,奶牛体况在1周时间内变化范围一般最大为0.25<sup>[19]</sup>,故对每头奶牛体况得分的时间序列进行分析,剔除人工评分时间序列中的异常值。最终得到包含300头奶牛的8 972幅体况图像及对应的BCS数据集。8 972幅图像经过兽医专家的标注,被分到5个类别当中,分别是3.25、3.50、3.75、4.00、4.25,分类样本如图2所示,可见随着BCS的递增尾部的形状特征从中空到凹陷,从扁平到膨胀;尾根两侧的凹陷面积也越来越小,从严重凹陷到完全看不到凹陷。由于评分为1.0和2.0的奶牛身体健康状态极差,在当下规模化养殖农场中很难找到;此外,体况评分在4.5~5.0的奶牛属于高危牛群。故采集的绝大多数奶牛体况评分数值分布在3.25~4.25。数据集按照9:1的比例随机划分为训练集和验证集,其中训练集和验证集当中的BCS分布特性如表1所示,数据集在随机划分过程中包含所有的BCS值,且保留了整体数据集的样本分布特性。

表1 不同BCS对应的数据集图像样本数分布

Table 1 Image distribution of data sets corresponding to different BCS values

BCS等级 BCS level	训练集 Training set	验证集 Verification set	总计 Total
3.25	868	96	964
3.50	2 338	259	2 597
3.75	1 896	210	2 106
4.00	1 791	198	1 889
4.25	1 185	131	1 316
总计 Total	8 078	894	8 972

练过程中梯度变化异常,达到缩短训练时间的目的。本研究采取的标准化处理方法如下:

$$X^* = \frac{x - \mu}{\sigma} \quad (1)$$

式(1)中,  $x$  为通道的像素值,  $\mu$  为通道像素值的均值,  $\sigma$  为通道像素的方差。即将  $R$ 、 $G$ 、 $B$  3 通道先归一化到 0 与 1 之间, 然后各个通道再减去均值除以方差, 式(1)中  $\mu$  和  $\sigma$  采用 ImageNet 数据集的均值和方差,  $\mu = [0.485, 0.456, 0.406]$ ,  $\sigma = [0.229, 0.224, 0.225]$ 。最终样本数据量为 11 663 张, 训练集和验证集保持 9:1 比例。

### 1.3 基于 Shuffle-ECANet 的奶牛 BCS 评价网络模型

本研究采用一种改进轻量级注意力机制网络模型 (Shuffle-ECANet)。该模型主要包括 ShuffleNet-v2 1×网络<sup>[20]</sup>、ECA 注意力模块<sup>[21]</sup>和 H-Swish 激活函数, 最后通过模型裁剪减少参数量和计算量的消耗。

1) ShuffleNet-v2 1×的特点。图 3 为 ShuffleNet-v2 1×网络的基本单元, 首先将特征图在通道维度上划分成 2 个分支, 并使用 1×1 卷积代替逐点组卷积, 2 个分支经过多层卷积操作后输入和输出通道数不变, 再对分支拼接后用通道混洗加强分支之间的信息交流。

2) ECA 注意力模块。本研究提出的 ECACConv 2 个基本单元以 ShuffleNet-v2 1×单元结构为基础进行改进, 分别加入 ECA 注意力模块。ECA 注意力模块的优点是参数量较少保证了网络的轻量级, 并且局部跨通道的信息交互能够带来明显效果提升。

3) H-Swish 激活函数。原始的 ShuffleNet-v2 1×网络使用 ReLU 激活函数, 如式(2)所示, 函数图像如图 4A 所示。ReLU 激活函数在负半区的导数为 0, 使得负半区的神经元输出为 0, 节省计算量和加大网络的稀疏性, 并且减少参数的相互依存关系, 缓解了过拟合问题的发生。但负半区的神经元在参数更新后梯度一直为 0, 这种现象被称为神经元“失活”。

$$\text{ReLU}(x) = \max(0, x) = \begin{cases} x, & \text{if } x < 0 \\ 0, & \text{otherwise} \end{cases} \quad (2)$$

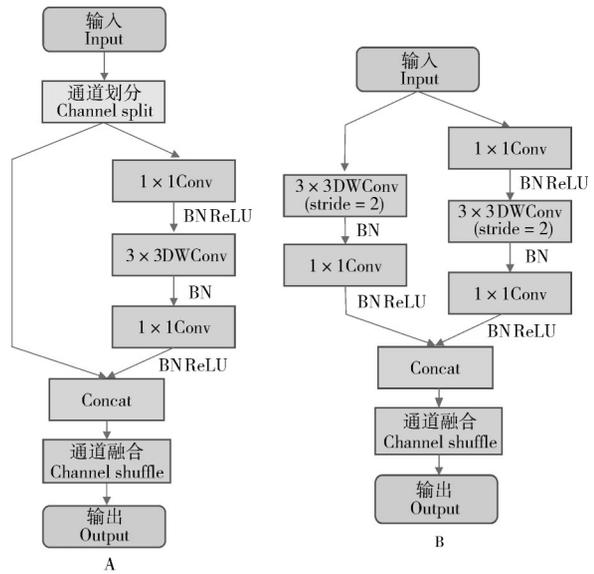
$$\text{Sigmoid}(x) = \sigma(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

$$\text{ReLU6}(x) = \min(\max(0, x), 6) \quad (4)$$

由公式(2)和(3)可得如下:

$$\text{H-Sigmoid}(x) = \frac{\text{ReLU6}(x+3)}{6} \quad (5)$$

$$\text{Swish}(x) = x \cdot \sigma(x) \quad (6)$$



A: ShuffleNet-v2 unit1; B: ShuffleNet-v2 unit2. Concat 表示张量拼接, Conv 表示卷积, DWConv 表示深度可分离卷积, stride 代表步长, 3×3、1×1 代表卷积核的尺寸, BN、ReLU 表示归一化和激活函数, 下同。Concat represents tensor splicing, Conv represents convolution, DWConv represents deep separable convolution, stride represents step size, 3×3, 1×1 represents the size of convolution kernel, BN and ReLU represent normalization and activation functions. The same as below.

图 3 ShuffleNet-v2 1× 单元

Fig.3 ShuffleNet-v2 1× unit

$$\text{H-Swish}(x) = x \cdot \frac{\text{ReLU6}(x+3)}{6} = \begin{cases} 0, & \text{if } x \leq -3 \\ x, & \text{if } x \geq 3 \\ x \cdot \frac{x+3}{6}, & \text{otherwise} \end{cases} \quad (7)$$

Swish 激活函数如式(6), 优于 ReLU 激活函数, 显著提高了神经网络的准确性, 但由于计算、求导复杂, 对量化过程不友好, 类比 Sigmoid 与 H-Sigmoid 激活函数, MobieNet-v3<sup>[22]</sup>中提出近似的 H-Swish 激活函数, 如式(7)所示, 该函数可以有效解决 ReLU 中会出现的神经元“坏死”问题, 且求导简单, 在实践中, 表现性能优越, 推理速度几乎不变。

4) ECACConv 单元。本试验使用的奶牛体况数据集具有背景复杂、判断奶牛体况区域的面积大小不一, 判断奶牛体况的区域分布广等特点, 面对该类型的数据集, ShuffleNet-v2 1×存在感兴趣区域分散且特征提取尺度单一等问题。因此, 本试验针对 ShuffleNet-v2 1×识别复杂背景下奶牛体况评分准确率以及模型参数存在的不足, 对 ShuffleNet-v2 1×模型的基本单元进行一系列的改进, 改进单元为

ECACConv(图4)。如图4A所示,在ECACConv unit1中,在 $3 \times 3$ 深度卷积之后添加ECA模块,并且能有效缓解梯度消失和防止过拟合问题。ECACConv unit设计特点:引入了参数量较少的ECA模块降低计算复杂度,并能够保证输入和输出通道相等使得访问成本(MAC)最小,并使用H-Swish激活函数,能有效缓解梯度消失和防止过拟合。

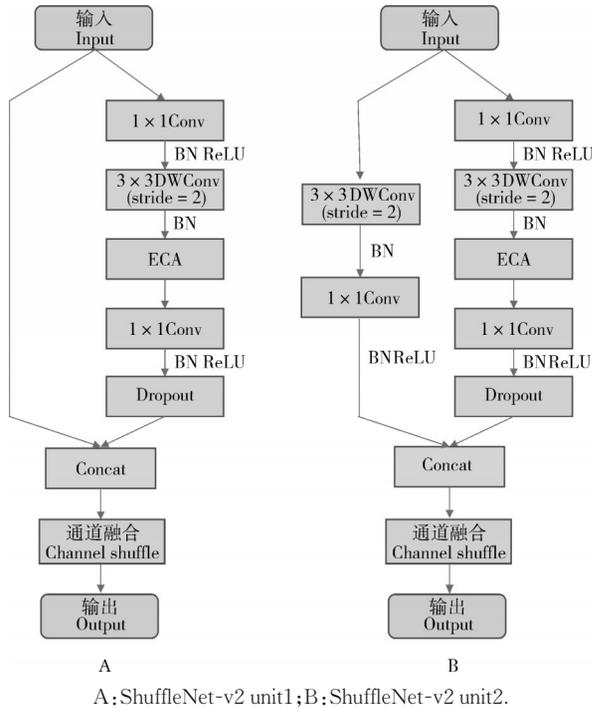


图4 ECACConv 单元

Fig.4 ECACConv unit

5)模型裁剪。模型中引入上述改进策略提升识别性能的同时增加了网络的负担。ShuffleNet-v2  $1 \times$ 模型是针对ImageNet数据集的1000类别进行分类设计的,而本研究只需要对5种奶牛体况图像数据进行分类,分类任务相对简单,所需的网络模型深度不需要太深。因此,为了减少参数量和计算量的消耗,将模型中ECACConv unit1的堆叠个数都降为3个。

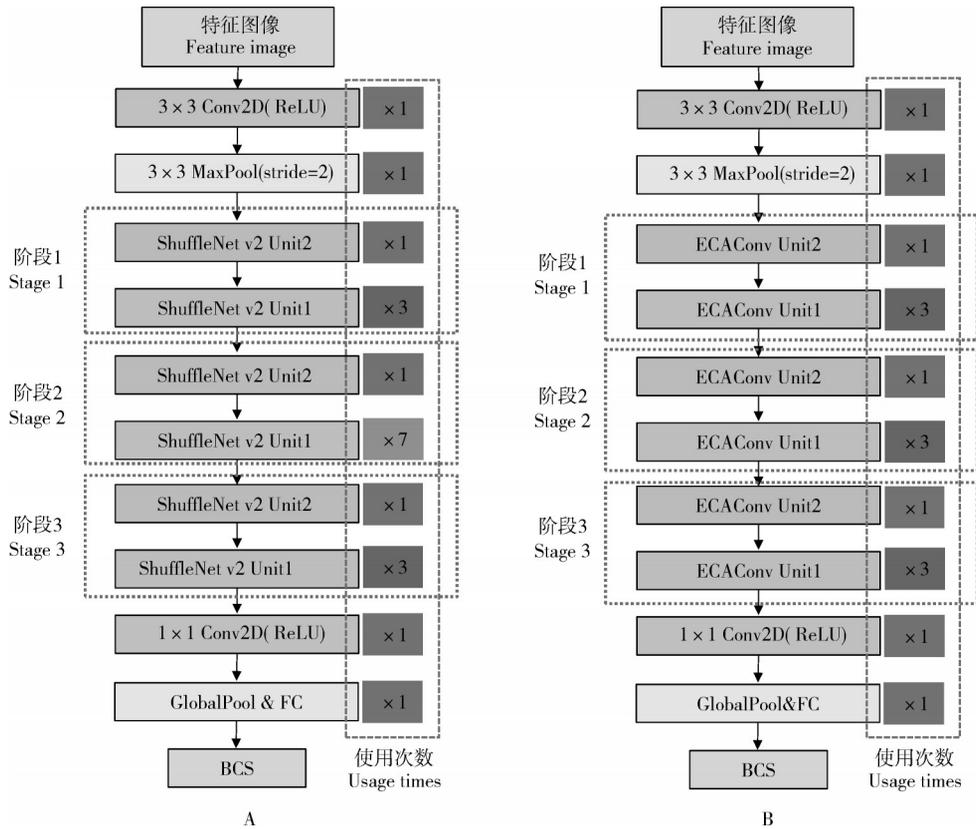
6)模型结构对比。ShuffleNet-v2  $1 \times$ 网络结构如图5A所示,输入特征图大小 $3 \times 224 \times 224$ ,先采用24个步长为2的 $3 \times 3$ 普通卷积进行特征提取,接着使用最大池化层进行下采样;随后,连续使用3个由ShuffleNet-v2  $1 \times$ unit2和ShuffleNet-v2  $1 \times$ unit1组成的模块层,模块层中unit2与unit1的数量分别为1:3、1:7、1:3;再使用1024个步长为1的 $1 \times 1$ 卷积扩充通道数,通过大通道大卷积的大感受野来获取奶牛体况特征信息;最后在全连接层前使用全局池

化层融合空间信息,防止过拟合,提高泛化能力。ShuffleNet-v2  $1 \times$ 当中的Stage1、Stage2、Stage3模块的通道数分别为116、232、464。本研究所提改进网络模型Shuffle-ECANet结构如图5B所示,与ShuffleNet-v2  $1 \times$ 网络相比,使用ECACConv模块,并用ECACConv Unit替换ShuffleNet-v2 Unit;采取减少每个Stage模块中ECACConv Unit1使用个数,来减少网络参数并保持性能;并且使用H-Swish激活函数,能有效缓解梯度消失和防止过拟合。为了减少参数量和计算量的消耗,将模型中ECACConv Unit1的堆叠个数都降为3个。

7)试验平台与参数设置。试验均在Windows 10的64位系统环境下运行,采用能够支持GPU加速和动态神经网络的Pytorch 1.11版本的深度学习开源框架,配合CUDA 11.4进行训练。计算机搭载的处理器为Intel(R) Core(TM) i5-10400F CPU @ 2.90 GHz,内存为16 GB,显卡为GTX3060。试验过程中将数据集按9:1比例划分为训练集和测试集,分别用作模型的训练与测试。输入奶牛尾部图像尺寸均设置为 $224 \text{像素} \times 224 \text{像素}$ ,受硬件条件约束的批处理大小(BatchSize)则设置为32,模型迭代次数共计100 epoch。为了模型的识别准确率能够更好地收敛,所涉及的试验采用了学习率衰减策略,初始学习率设置为0.01,所有的训练模型采用SGD优化器,其参数设置为默认。本研究中选用EfficientNet-v1、MobileNet-v3、ShuffleNet-v2  $1 \times$ 、ResNet34作为对比模型,来评价本研究方法的整体性能。

8)模型评价指标。奶牛体况为多分类任务,并且存在分类样本不均衡的问题,因此,混淆矩阵可以直观体现模型分类的能力。基于混淆矩阵引入多个模型评价指标:准确率(accuracy,  $A$ ),即样本预测正确的数量占总数量的比例。精确率(precision,  $P$ ),各类别精确率的平均值为评价指标。召回率(recall,  $R$ )各类别召回率的平均值为评价指标。 $F_1$ 值是精确率与召回率的调和平均值,用于评价模型对极端BCS类别的分类能力。此外,对于特定奶牛体况分类任务,模型除了需要满足一定的精度要求外,也需要满足模型移植至移动端所需的低内存消耗等要求,因此模型参数量也是模型对比的评价指标。其中, $T_p$ 指被模型预测为正类的正样本; $T_N$ 指被模型预测为负类的负样本; $F_p$ 指被模型预测为正类的负样本; $F_N$ 指被模型预测为负类的正样本。

准确率对于数据集均衡,在数据集不平衡时,准



A: ShuffleNet-v2 1×; B: Shuffle-ECANet. Conv2D 表示步长为 2 的卷积, GlobalPool&FC 表示全局池化和全连接。Conv2D represents convolution with step size of 2, GlobalPool&FC represents global pooling and full connection, and ReLU represents activation function.

图 5 网络模型结构

Fig.5 Architecture of network model

准确率将不能很好地表示分类模型的优劣性能,此时应参考其他评价指标,其计算公式为:

$$A = \frac{T_p + T_n}{T_p + T_n + F_p + F_n} \quad (8)$$

精确率是针对预测结果的一个评价指标,即在模型预测为正样本的结果中正确预测样本所占的比例,由于奶牛体况为多分类问题,因此使用各 BCS 类别精确率的平均值作为评价指标,其计算公式为:

$$P = \frac{T_p}{T_p + F_p} \quad (9)$$

召回率是针对原始样本而言的一个评价指标,在实际为正样本中被预测为正样本所占的比例,同理使用各 BCS 类别召回率的平均值作为评价指标,其计算公式为:

$$R = \frac{T_p}{T_p + F_n} \quad (10)$$

$F_1$  值是精度与召回率的调和平均值,可以兼顾精确率和召回率,其计算公式为:

$$F_1 = \frac{2}{\frac{1}{P} + \frac{1}{R}} \quad (11)$$

网络参数量,模型除了需要满足一定的精度要求外,也需要满足模型移植至移动端所需的低内存消耗等要求,因此模型参数量也是模型对比的评价指标。

## 2 结果与分析

### 2.1 混淆矩阵

Shuffle-ECANet 网络评分结果的混淆矩阵如图 6 所示,由混淆矩阵主对角线的样本数量可知,本研究提出的轻量级 Shuffle-ECANet 模型对各类别识别准确率在 97% 以上,证明了该模型能够有效区别奶牛各类别的体况。其次主对角线及其两侧样本数量达到 99% 以上,表明该模型在误差范围大于 0.25 时能够准确进行分类,精度提高的优越性为大规模牧场中个体奶牛体况精细化管理提供了可能。3.50 和 3.75 类别相比其他类别准确率呈现下降的问题,可能与 2 种类别在 2D 图像中特征难以捕捉以及两者分类特征相近难以进行有效判断有关。

3.25	95	3	0	0	0
3.50	1	256	3	1	0
3.75	0	0	207	1	0
4.00	0	0	0	196	1
4.25	0	0	0	0	130
	3.25	3.50	3.75	4.00	4.25

图6 Shuffle-ECANet网络评分结果的混淆矩阵

Fig.6 Confusion matrix of scoring results by Shuffle-ECANet

2.2 模型评价

表2为不同误差范围内不同BCS对应的模型精准率、召回率及F<sub>1</sub>值。对于精确率(P)而言,BCS在误差范围为0~0.25时,极端BCS的精确率要高于中间BCS,此结果与赵凯旋等<sup>[17]</sup>研究结果一致。BCS在3.75时取得最低精度97.6%,误差范围为0.25和0.50时,BCS的精确率实现了提高,其中BCS为3.75提升最大。对于召回率而言,误差范围为0时极端BCS表现出相反的结果,这是由于3.25的数据集样本数量最少,中间BCS全部召回率达到了98%以上,中间BCS的高召回率有利于牧场对奶牛体况及时调整,增加经济效益。误差范围扩大到0.25时,BCS在各个类别召回率都达到了99%以上。对于F<sub>1</sub>值而言,误差范围为0时,各类别BCS的F<sub>1</sub>值呈现递增趋势,并且波动范围较小,证明了该模型在兼顾精确率和召回率方面表现优异,与现有研究相比取得了一定进展。误差范围为0.25和0.50时,各类别BCS的精准率、召回率及F<sub>1</sub>均达到了99%。

表2 基于深度学习的体况评分方法的评价结果

Table 2 Evaluation index of physical condition scoring method based on deep learning %

BCS	误差 Error								
	0			0.25			0.50		
	P	R	F <sub>1</sub>	P	R	F <sub>1</sub>	P	R	F <sub>1</sub>
3.25	98.9	96.9	97.9	100	100	100	100	100	100
3.50	98.8	98	98.4	100	99.6	99.8	100	100	100
3.75	97.6	99.5	98.6	100	100	100	100	100	100
4.00	98.9	98.5	98.7	99.5	100	99.7	100	100	100
4.25	99.2	100	99.6	100	100	100	100	100	100

2.3 模型对比

为了验证本研究方法的性能,将所提出的Shuffle-ECANet模型与EfficientNet-v1、MobileNet-v3、

ShuffleNet-v2 1×、ResNet34进行对比分析,混淆矩阵结果如表3所示。4种模型的主对角线分布情况差异性较低,预测样本数量集中分布于主对角线两侧以内,都在3.5类别上表现出了较差的预测效果,对各类别的预测准确率都呈现由高到低再到高的变化趋势。针对不同BCS类别,4种模型分类能力各不相同,其中MobileNet-v3、EfficientNet-v1模型对于3.50类别表现均不如其他类别的准确率,ShuffleNet-v2 1×模型在所有类别中准确率最低。对于3.75和4.25类别而言,4种模型的类别准确率从高到低依次为EfficientNet-v1、ResNet34、MobileNet-v3、ShuffleNet-v2 1×;而在BCS为3.5和4.0时,ResNet34和EfficientNet-v1模型均优于ShuffleNet-v2 1×和MobileNet-v3。不同网络模型之间的网络结构不同网络模型提取数据集中体况特征的能力存在差异。

表3 各算法得到的混淆矩阵结果

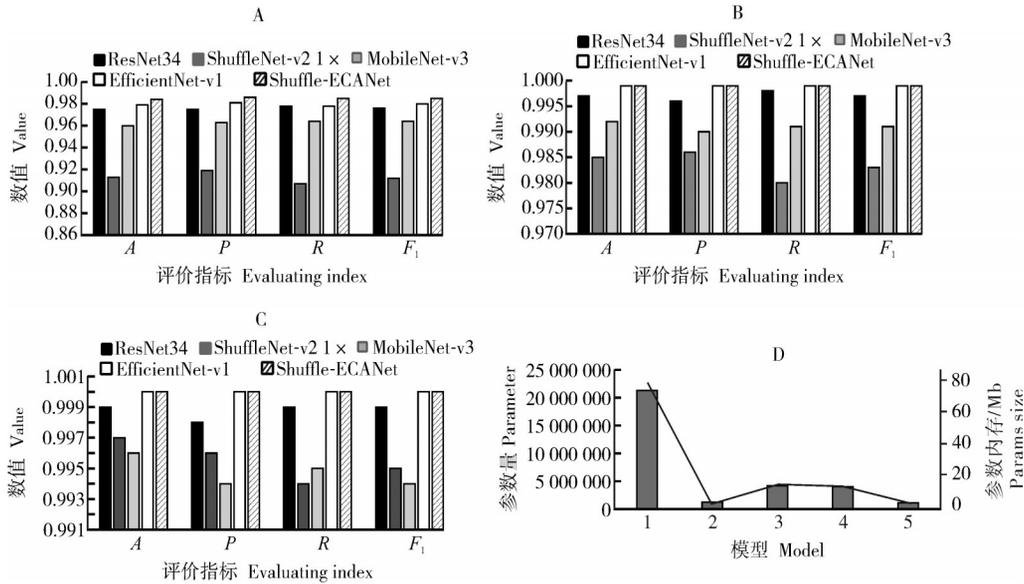
Table 3 The confusion matrix obtained by each algorithm

模型 Model	BCS	3.25	3.50	3.75	4.00	4.25
EfficientNet-v1	3.25	94	4	0	0	0
	3.50	2	250	0	1	0
	3.75	0	5	208	3	0
	4.00	0	0	2	193	0
	4.25	0	0	0	1	131
MobileNet-v3	3.25	94	1	0	1	0
	3.50	0	246	1	0	1
	3.75	1	9	202	6	0
	4.00	1	2	7	190	3
	4.25	0	1	0	1	127
ShuffleNet-v2 1×	3.25	89	10	3	1	1
	3.50	6	240	9	3	0
	3.75	0	9	185	9	0
	4.00	0	0	9	176	3
	4.25	1	0	4	9	127
ResNet34	3.25	93	2	0	0	0
	3.50	3	254	1	2	1
	3.75	0	3	204	4	0
	4.00	0	0	5	192	1
	4.25	0	0	0	0	129

为进一步分析5种网络的模型性能,依据测试集样本分类的混淆矩阵,采用本研究“1.3.8)”定义的指标对5种网络进行综合评估。评估结果如图7所示,其中图7A~C分别是BCS误差为0、0.25、0.50时,准

准确率  $A$ 、精确率  $P$ 、召回率  $R$ 、 $F_1$  值评价指标对比分析结果,图 7D 为参数量的对比分析结果。由图 7A 可知,BCS 误差为 0 时,模型的优劣顺序为 Shuffle-ECANet、EfficientNet-v1、ResNet34、MobileNet-v3、ShuffleNet-v2 1×。由图 7B、C 可知,缩小误差范围时,同为轻量级网络模型的 MobileNet-v3 和 ShuffleNet-v2 1× 各项指标下降幅度大于 Shuffle-EC-

ANet 模型,虽然模型 EfficientNet-v1 和 ResNet34 在误差范围 0~0.25 时保持较好的分类效果,但是 ResNet34 的参数量远超 Shuffle-ECANet, EfficientNet-v1 参数量约为 Shuffle-ECANet 的 2 倍。综合上述分析可知,5 种模型中,Shuffle-ECANet 模型具有更高的体况识别准确率,可实现奶牛体况的精准高效识别。



A: 误差为 0 The error is 0; B: 误差为 0.25 The error is 0.25; C: 误差为 0.50 The error is 0.50; D: 参数量和模型大小 Parameter quantity and model size. 1. ResNet34; 2. ShuffleNet-v2 1×; 3. MobileNet-v3; 4. EfficientNet-v1; 5. Shuffle-ECANet.

图 7 不同误差条件下各网络模型的识别结果

Fig.7 Identification results of each network model under different errors

### 3 讨论

本研究针对奶牛体况评分分类任务,提出一种改进 ShuffleNet-v2 1× 的轻量级奶牛体况方法。分析了 ShuffleNet-v2 1× 轻量级网络卷积设计特点即卷积输入和输出通道相等时内存访问成本(MAC)最小,分组卷积通过通道之间的稀疏连接来降低计算复杂度,但分组数太多的卷积会增加 MAC;将 ECA (efficient channel attention) 注意力模块引入原 ShuffleNet-v2 1× 的基础单元,该模块在不降维的情况下,直接将输入的特征图进行全局平均池化(global average pooling, GAP),避免了降维对通道注意力学习的不利影响,接着通过快速 1D 卷积实现对每个通道及其邻近通道的局部跨通道信息交互,避免对所有通道进行信息交流产生低效的冗余信息。但引入 ECA 模块增加了网络的计算负担,因此减少了改进单元的数量,该模型方法在参数量和准确率之间达

到了良好的平衡。由于神经网络训练往往需要大量的数据集才能达到较好的效果,而现有的每个类别的样本数据较少,因此,采用数据增强方法进行数据扩增,其中数据增强方法包括随机平移(平移距离随机产生)、水平翻转、随机旋转(旋转角度随机生成,模拟识别设备的不同拍摄角度)、随机亮度和随机对比度(随机范围均为 0.5~1.5,模拟真实饲养环境下不同的光照条件)等,数据增强方法可以训练出更加适合奶牛体况评分应用的网络模型。改进后的模型,与原始模型 ShuffleNet-v2 1× 相比,改进模型对奶牛体况评分识别准确率提升 7.5 百分点;与经典卷积神经网络架构进行对比,改进模型具有更出色的识别性能以及更少的参数,从而减少了模型的内存,便于在价格要求低廉的场景中应用。下一步将重点研究如何在养殖圈舍自然环境下奶牛体况的精准高效评分,进一步推动奶牛体况商业化发展。

## 参考文献 References

- [1] KADARMIDEEN H N. Genetic correlations among body condition score, somatic cell score, milk production, fertility and conformation traits in dairy cows[J]. *Animal science*, 2004, 79(2): 191-201.
- [2] ROCHE J R, MACDONALD K A, SCHÜTZ K E, et al. Calving body condition score affects indicators of health in grazing dairy cows[J]. *Journal of dairy science*, 2013, 96(9): 5811-5825.
- [3] ROCHE J R, MACDONALD K A, BURKE C R, et al. Associations among body condition score, body weight, and reproductive performance in seasonal-calving dairy cattle[J]. *Journal of dairy science*, 2007, 90(1): 376-391.
- [4] 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.
- [5] BEWLEY J M, PEACOCK A M, LEWIS O, et al. Potential for estimation of body condition scores in dairy cattle from digital images[J]. *Journal of dairy science*, 2008, 91(9): 3439-3453.
- [6] 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.
- [7] EL-SHARAWY M E, MASHALY I M, SHUKRY M, et al. Influence of body condition score on blood metabolites and oxidative stress in pre- and post-calving of Friesian dairy cows in Egypt[J/OL]. *Slovenian veterinary research*, 2019, 56(22-Suppl)[2022-08-11]. <https://doi.org/10.26873/SVR-759-2019>.
- [8] 王玉洁, 霍鹏举, 孙雨坤, 等. 体况评分在奶牛生产中的研究进展[J]. *动物营养学报*, 2018, 30(9): 3444-3452. WANG Y J, HUO P J, SUN Y K, et al. Research progress of body condition score in dairy cow production[J]. *Chinese journal of animal nutrition*, 2018, 30(9): 3444-3452 (in Chinese with English abstract).
- [9] 李喜阳, 李信颖, 赵志超, 等. 基于机器学习方法的母猪高低产分类模型研究[J]. *华中农业大学学报*, 2021, 40(3): 221-229. LI X Y, LI X J, ZHAO Z C, et al. Research on sow high and low yield classification model based on machine learning method[J]. *Journal of Huazhong Agricultural University*, 2021, 40(3): 221-229 (in Chinese with English abstract).
- [10] 吴伟斌, 唐婷, 刘强, 等. 基于语义分割的山地果茶园道路识别技术研究[J]. *华中农业大学学报*, 2022, 41(1): 246-254. WU W B, TANG T, LIU Q, et al. Semantic segmentation based road recognition technology of hilly fruit and tea garden[J]. *Journal of Huazhong Agricultural University*, 2022, 41(1): 246-254 (in Chinese with English abstract).
- [11] SUN Yong, 王译霄, 宣晓婷, 等. 基于机器学习联合网络爬虫算法的果汁鉴伪技术的研究进展[J]. *华中农业大学学报*, 2022, 41(1): 269-276. SUN Y, WANG Y X, XUAN X T, et al. Progress of fruit juices authenticity technology based on machine learning and web crawler algorithm[J]. *Journal of Huazhong Agricultural University*, 2022, 41(1): 269-276 (in Chinese with English abstract).
- [12] 孙俊, 朱伟栋, 罗元秋, 等. 基于改进 MobileNet-V2 的田间农作物叶片病害识别[J]. *农业工程学报*, 2021, 37(22): 161-169. SUN J, ZHU W D, LUO Y Q, et al. Recognizing the diseases of crop leaves in fields using improved MobileNet-V2[J]. *Transactions of the CSAE*, 2021, 37(22): 161-169 (in Chinese with English abstract).
- [13] GYO Y, ZHANG Z, HE D, et al. Detection of cow mounting behavior using region geometry and optical flow characteristics[J/OL]. *Computers and electronics in agriculture*, 2019, 163: 104828 [2022-08-11]. <https://doi.org/10.1016/j.compag.2019.05.037>.
- [14] RODRÍGUEZ ALVAREZ 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.
- [15] SONG X, BOKKERS E A M, VAN DER TOL P P J, et al. Automated body weight prediction of dairy cows using 3-dimensional vision[J]. *Journal of dairy science*, 2018, 101(5): 4448-4459.
- [16] 黄小平. 基于多传感器的奶牛个体信息感知与体况评分方法研究[D]. 合肥: 中国科学技术大学, 2020. HUANG X P. Individual information perception and body condition score assessment for dairy cow based on multi-sensor[D]. Hefei: University of Science and Technology of China, 2020 (in Chinese with English abstract).
- [17] 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 K X, LIU X H, JI J T. Automatic body condition scoring method for dairy cows based on EfficientNet and convex hull feature of point cloud[J]. *Transactions of the CSAM*, 2021, 52(5): 192-201 (in Chinese with English abstract).
- [18] SUN Y K, HUO P J, WANG Y J, 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.
- [19] BERRY D P, BUCKLEY F, DILLON P, et al. Genetic relationships among body condition score, body weight, milk yield, and fertility in dairy cows[J]. *Journal of dairy science*, 2003, 86(6): 2193-2204.
- [20] MA N, ZHANG X, ZHENG H T, et al. ShuffleNet V2: practical guidelines for efficient CNN architecture design[M]. Cham: Springer International Publishing, 2018: 122-138.
- [21] WANG Q L, WU B G, ZHU P F, et al. ECA-net: efficient channel attention for deep convolutional neural networks[C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA. IEEE: 11531-11539.

- [22] HOWARD A, SANDLER M, CHEN B, et al. Searching for MobileNetV3[C]//IEEE.2019 IEEE/CVF International Conference on Computer Vision (ICCV).Seoul:IEEE,2019:1314-1324.

## Application of lightweight convolutional neural network in scoring body condition of dairy cows

CHENG Can<sup>1</sup>, FENG Tao<sup>1</sup>, HUANG Xiaoping<sup>1</sup>, GUO Yangyang<sup>1</sup>, LIANG Dong<sup>1</sup>, SHI Daoling<sup>2</sup>

1.School of Internet Technology, Anhui University, Hefei 230039, China;

2.School of Electronic and Communication Engineering, Anhui Xinhua University, Hefei 230088, China

**Abstract** The body condition score (BCS) of dairy cows is one of the important indicators of animal health and welfare in precision animal husbandry farm, and an important basis for decision-making and management. Traditional methods of assessing body condition are mainly manual assessments. The traditional method is manual evaluation, which relies on human visual or tactile scoring evaluation of specific areas of the cow's body. Although the cost of manual method is low, it is time-consuming and labor-consuming. The manual evaluation has the disadvantages of subjectivity and low repeatability of scoring results. With the development of artificial intelligence, deep learning technology has been widely used in monitoring animal information. However, there is still a need for an efficient and real-time method of monitoring body condition of cow to meet the needs of commercialization. An improved lightweight attention mechanism network model (Shuffle-ECANet) was proposed to solve the problems mentioned above. Firstly, 8 972 image samples containing the tail of cows were selected, and the body condition of cows was manually scored by animal husbandry experts to construct a relevant dataset. Then, an efficient channel attention module was introduced into the feature extraction structure of lightweight ShuffleNet-v2 to strengthen the network's ability to extract body condition features of cow. The H-Swish activation function was used to avoid neuronal necrosis. Finally, the Shuffle-ECANet network model was obtained by further simplifying the network structure. Three evaluation indicators including precision, recall, and  $F_1$  were selected to evaluate the performance of models. Four models including EfficientNet-v1, MobileNet-v3, ShuffleNet-v2  $1\times$  and ResNet34 were used for comparative analysis to verify the performance of Shuffle-ECANet network model. The results showed that the Shuffle-ECANet model outperformed EfficientNet-v1, MobileNet-v3, ShuffleNet-v2  $1\times$  and ResNet34 in the results of evaluating body condition with BCS estimations within 0, 0.25 and 0.50 units, respectively. The effectiveness of Shuffle-ECANet method was proved as well. The lightweight Shuffle-ECANet model proposed had an accuracy of more than 97% for each category, indicating that the model can distinguish different body conditions of cows effectively. It will provide the possibility for the refined management of individual body condition of dairy cows in large-scale pastures and a basis for the future application in low-computing power equipment, and a theoretical basis and idea for the commercialization of scoring body condition of cow.

**Keywords** body condition score; ShuffleNet-v2 network; attention mechanism; smart breeding; lightweight; activation function

(责任编辑:陆文昌)