

# 基于 VGG – ST 模型的奶牛粪便形态分类方法研究

纪宝峰<sup>1,2</sup> 李斌<sup>1,2</sup> 卫勇<sup>2</sup> 赵文文<sup>1</sup> 周孟创<sup>1</sup>

(1. 北京市农林科学院智能装备技术研究中心, 北京 100097; 2. 天津农学院工程技术学院, 天津 300384)

**摘要:** 快速准确识别奶牛粪便形态, 对于奶牛肠胃健康监测与精细管理具有重要意义。针对目前奶牛粪便识别人工依赖强、识别难度大等问题, 提出了一种基于 VGG – ST (VGG – Swin Transformer) 模型的奶牛稀便、软便、硬便及正常粪便图像识别与分类方法。首先, 以泌乳期荷斯坦奶牛粪便为研究对象, 采集上述 4 种不同形态的粪便图像共 879 幅, 利用翻转、旋转等图像增强操作扩充至 5 580 幅作为本研究数据集; 然后, 分别选取 Swin Transformer、AlexNet、ResNet – 34、ShuffleNet 和 MobileNet 5 种典型深度学习图像分类模型进行奶牛粪便形态分类研究, 通过对比分析, 确定 Swin Transformer 为最优基础分类模型; 最后, 融合 VGG 模型与 Swin Transformer 模型, 构建了 VGG – ST 模型, 其中, VGG 模型获取奶牛粪便局部特征, 同时 Swin Transformer 模型提取全局自注意力特征, 特征融合后实现奶牛粪便图像分类。实验结果表明, Swin Transformer 模型在测试集中分类准确率达 85.9%, 与 ShuffleNet、ResNet – 34、MobileNet、AlexNet 模型相比分别提高 1.8、4.0、12.8、23.4 个百分点; VGG – ST 模型分类准确率达 89.5%, 与原 Swin Transformer 模型相比提高 3.6 个百分点。该研究可为奶牛粪便形态自动筛查机器人研发提供方法参考。

**关键词:** 奶牛; 粪便分类; Swin Transformer; 深度学习

中图分类号: TP391.41 文献标识码: A 文章编号: 1000-1298(2023)S1-0245-07

## Cow Manure Classification Method Based on VGG – ST Model

JI Baofeng<sup>1,2</sup> LI Bin<sup>1,2</sup> WEI Yong<sup>2</sup> ZHAO Wenwen<sup>1</sup> ZHOU Mengchuang<sup>1</sup>

(1. Intelligent Equipment Research Center, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China

2. College of Engineering and Technology, Tianjin Agricultural University, Tianjin 300384, China)

**Abstract:** Accurate and rapid identification of cow manure morphology is of great significance for monitoring and precise management of cow gastrointestinal health. In response to the problems of strong artificial dependence and difficulty in identification in current cow manure recognition methods, a method for identifying cow thin, loose, hard, and normal manure was proposed based on the VGG – ST (VGG – Swin Transformer) model. Firstly, a total of 879 images of the four different forms of manures was collected from lactating Holstein cows and augmented to 5 580 images using operations such as flipping and rotation as the dataset. Then, five typical deep learning image classification models, namely Swin Transformer, AlexNet, ResNet – 34, ShuffleNet and MobileNet, were selected for cow manure classification research. Through comparative analysis, Swin Transformer was determined to be the optimal base classification model. Finally, the VGG – ST model combined the VGG model with the Swin Transformer model. The VGG model was utilized to capture local features of cow manure, while the Swin Transformer model extracted global self-attention features. After feature concatenation, the cow manure images were classified. The experimental results showed that the Swin Transformer model achieved a classification accuracy of 85.9% on the testing set, which was 1.8 percentage points, 4.0 percentage points, 12.8 percentage points, and 23.4 percentage points higher than that of ShuffleNet, ResNet – 34, MobileNet, and AlexNet, respectively. The classification accuracy of the VGG – ST model was 89.5%, which was 3.6 percentage points higher than that of the original Swin Transformer model. The research result provided a method reference for the development of automatic inspection robots for cow manure morphology.

**Key words:** dairy cow; manure classification; Swin transformer; deep learning

收稿日期: 2023–06–30 修回日期: 2023–09–08

基金项目: 国家重点研发计划项目(2022YFD1301103)、河北省重点研发计划项目(22322909D)、北京市农林科学院改革与发展项目和北京市农林科学院智能装备技术研究中心开放项目(KFZN2020W011)

作者简介: 纪宝峰(1998—), 男, 硕士生, 主要从事畜禽表型研究, E-mail: 1336366295@qq.com

通信作者: 李斌(1983—), 男, 研究员, 主要从事畜牧智能装备研究, E-mail: lib@nercita.org.cn

## 0 引言

奶牛粪便形态可一定程度上反映肠胃功能、饲料消化吸收程度以及是否发生疾病<sup>[1]</sup>。通过对奶牛粪便形态的分析可优化日粮配比,改善肠胃健康状况,有效提高产奶量和饲料利用率<sup>[2]</sup>。现阶段,奶牛粪便鉴别主要依赖饲养人员肉眼观察,存在劳动强度大、易漏检等问题。随着我国奶牛养殖规模化、集约化发展<sup>[3]</sup>,奶牛粪便形态监测工作日益繁重,发展一种奶牛粪便形态自动监测与分类方法具有重要意义。

近年来,国内外学者已基于多种深度学习算法先后对人畜粪便开展了形态识别分类研究。闻涛<sup>[4]</sup>基于 StoolNet 模型开展了实验室环境下的人类粪便形状、颜色自动识别研究,识别准确率达 93.6%。HACHUEL 等<sup>[5]</sup>使用 ResNet 模型对粪便进行正常、便秘和腹泻三分类,准确率达 74.62%。WANG 等<sup>[6]</sup>分别使用 Faster R-CNN 和 YOLO v3 模型对肉鸡养殖舍内履带上鸡正常、形状异常、颜色异常、稀便和水样粪便进行五分类,最优分类精度分别达 93.3% 和 84.3%。目前,以 Swin Transformer<sup>[7]</sup>等模型为代表的新型分类模型因其抗干扰能力强、分类精度高及训练效率高等优点,在农作物识别<sup>[8-12]</sup>、障碍物检测<sup>[13-22]</sup>等研究领域展现出良好的分类性能,使其在解决复杂环境下目标识别与分类具有明显优势。

鉴于此,本文选取自然条件下奶牛粪便为研究对象,针对稀便、软便、硬便和正常粪便的自动分类问题,借助 Swin Transformer 模型获取图像全局信息,引入 VGG 模型<sup>[23]</sup>,捕捉奶牛粪便图像局部信息,通过信息融合,实现奶牛粪便精准、自动分类。

## 1 材料与方法

### 1.1 奶牛粪便形态类别定义

参照李建国等<sup>[24]</sup>奶牛粪便分类方法,按照形态将奶牛粪便分为稀便、软便、硬便和正常粪便 4 种类别,各类别定义如表 1 所示,各类粪便图像如图 1 所示。

表 1 奶牛粪便形态类别定义<sup>[24]</sup>

Tab. 1 Definition of cow manure category

粪便形态类别	粪便状况描述
稀便	粪便较稀,呈水样
软便	粪便较松软,难以成堆,地面时常伴有飞溅
硬便	粪便较为干燥,有时会结成块状
正常粪便	粪便堆积,中间较低或有凹陷

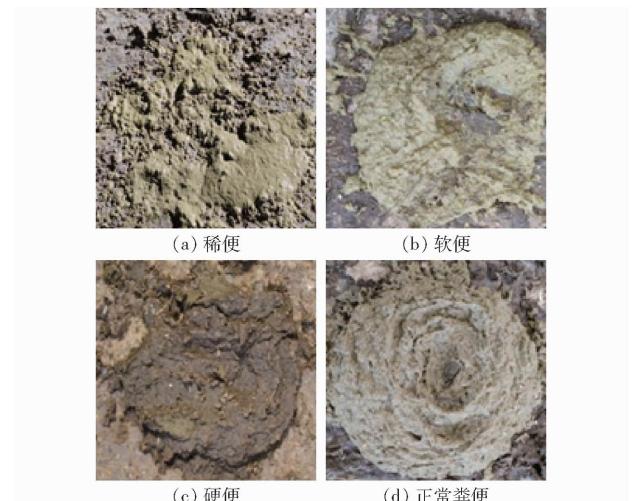


图 1 4 种形态奶牛粪便

Fig. 1 Four forms of cow manure

### 1.2 数据采集

先后于 2022 年 4 月 14—16 日与 2023 年 2 月 15—17 日,在北京市密云区康源奶牛养殖有限责任公司与北京市大兴区首农畜牧金银岛牧场泌乳牛舍内,采集泌乳期奶牛粪便图像。图像采集平台如图 2 所示,将索尼 FDR-AX100E 型摄像机固定于支架垂直地面拍摄,拍摄距离为 1.3 m,分辨率设置为 1 440 像素 × 1 080 像素。试验共采集 879 幅图像。

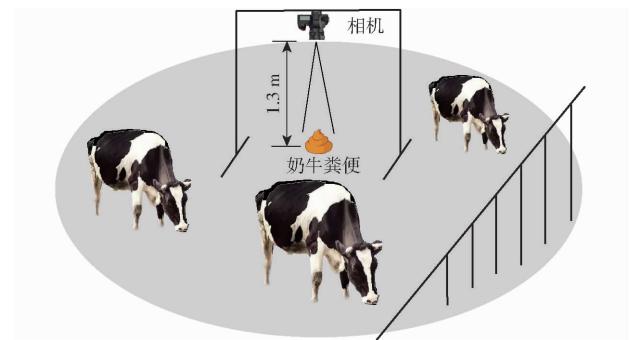


图 2 图像采集

Fig. 2 Image acquisition

### 1.3 数据集制作

为提高模型的泛化能力和鲁棒性,对数据集进行数据增强,具体包括图像翻转、旋转、亮度增强<sup>[25]</sup>、颜色增强<sup>[26]</sup>和对比度增强<sup>[27]</sup>,数据增强效果如图 3 所示。经数据增强将奶牛粪便图像数据集扩充至 5 580 幅,按照比例 6:2:2 划分为训练集、验证集和测试集,其中训练集 3 348 幅,验证集 1 080 幅,测试集 1 152 幅。表 2 为数据集中 4 种类别粪便图像分布情况。

### 1.4 VGG-ST 分类模型

为实现奶牛粪便精确分类,本研究提出 VGG-ST(VGG Swin Transformer)分类模型,利用 VGG 模

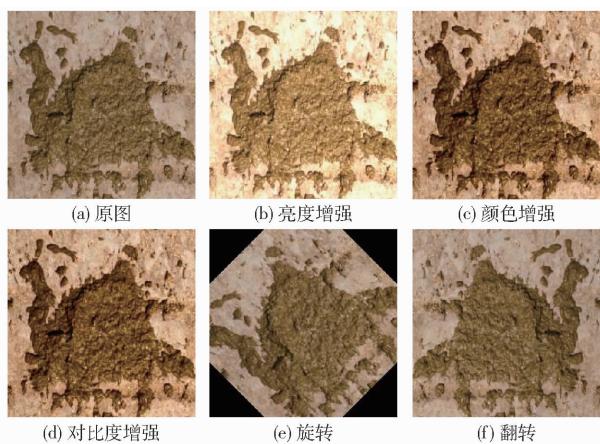


图 3 图像增强  
Fig. 3 Image enhancement

型捕捉图像中的局部特征,结合 Swin Transformer 模

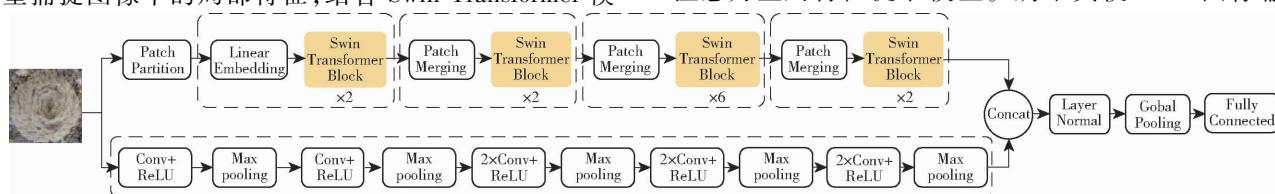


图 4 VGG-ST 模型框架  
Fig. 4 Framework of VGG-ST

入 Patch Partition 层进行切割,将切割后图像输入到 Linear Embedding 层映射到更高维度,再将图像输入到 Swin Transformer Block 中提取自注意力全局特征。Swin Transformer Block 如图 5 所示,其中包含 4 个 Layer Normalization 层、2 个 Multi-layer Perception、1 个窗口自注意力模块 (Windows multi-head self attention, W-MSA) 和 1 个移动窗口自注意力模块 (Shifted windows multi-head self attention,

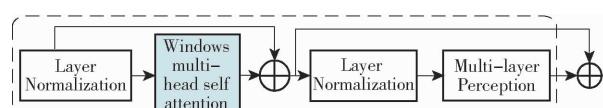


图 5 Swin Transformer Block 结构图  
Fig. 5 Swin Transformer Block structure diagram

W-MSA 和 SW-MSA 是 Swin Transformer Block 中 2 种窗口移动方式,如图 6a 所示。W-

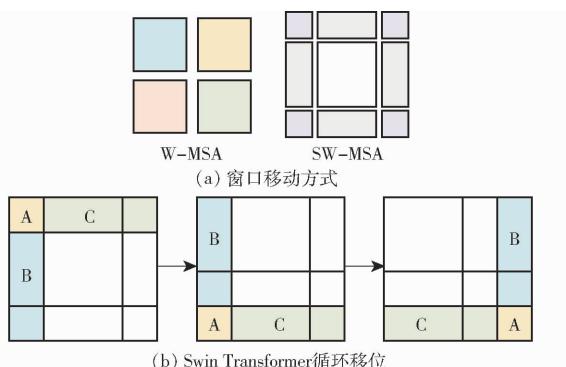


图 6 移动窗口多头自注意力  
Fig. 6 Shifted windows multi-head self attention

表 2 4 种粪便类别图像数量

Tab. 2 Image numbers of four types of manure

类别	原始图像数量	增强后图像数量	训练集数量	验证集数量	测试集数量
稀便	99	1 584	950	307	327
软便	324	1 296	778	251	267
硬便	36	1 440	864	279	297
正常粪便	420	1 260	756	244	260

型自注意力机制获取奶牛粪便图像的全局信息,特征融合后实现奶牛粪便的准确识别分类。VGG-ST 分类模型如图 4 所示。

#### 1.4.1 Swin Transformer 自注意力全局特征提取模型

为提升检测精度和效率,选取 Swin-T 作为自注意力全局特征提取模型。奶牛粪便 RGB 图像输

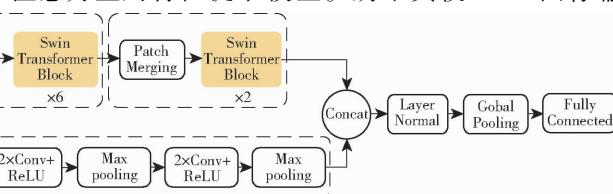


图 4 VGG-ST 模型框架  
Fig. 4 Framework of VGG-ST

SW-MSA), Swin Transformer Block 计算过程为

$$\hat{z} = \text{W-MSA}(\text{LN}(z^{l-1})) + z^l \quad (1)$$

$$z^l = \text{MLP}(\text{LN}(z^l)) + \hat{z} \quad (2)$$

$$z^{l+1} = \text{SW-MSA}(\text{LN}(z^l)) + z^l \quad (3)$$

$$z^{l+1} = \text{MLP}(\text{LN}(z^{l+1})) + \hat{z}^{l+1} \quad (4)$$

式中,  $\hat{z}$ 、 $z^l$  和  $z^{l+1}$  分别表示图像  $l$  经过 W-MSA、MLP 和 SW-MSA 输出的特征。LN 表示对输出特征进行层标准化操作。

MSA 模块将图像划分成 4 个窗口,每个窗口内部计算自注意力;SW-MSA 模块将图像划分为 9 个窗口,但由于窗口数量增加,且窗口尺寸不一,计算难度较大。因此 Swin Transformer 模型使用了一种循环移位方式解决此问题,如图 6b 所示。在分割后的 9 个窗口中选择 A、B、C 3 部分,经过图中所示方法移动窗口,使得图像重新变回 4 个窗口。完成自注意力计算后,为保持图像整体的相对位置以及语义信息不变,将位移后的图像还原,方便后续图像自注意力计算,最终获得奶牛粪便全局特征图像。

#### 1.4.2 VGG 局部特征提取模型

VGG 模型是由牛津大学视觉几何组 (Visual

geometry group, VGG) 提出的深度卷积神经网络模型, 通过增加网络深度和使用小尺寸卷积核, 更好地获取图像局部特征, 完成图像分类任务。为降低模型计算复杂度, 选用 VGG 模型中最小的 VGG11 模型与 Swin Transformer 模型形成并行双分支, 形成各分支优势互补, VGG11 模型如图 4 所示。图像经过多层卷积层、ReLU 层及 Max pooling 层后完成图像局部特征提取。舍弃 VGG11 模型后续用于分类的全连接层和 Softmax 层, 将局部特征图像与 Swin Transformer 模型获取的全局特征图像进行拼接融合, 得到包含全局特征和局部特征的特征图用于奶牛粪便图像分类。

### 1.5 评价指标

采用准确率(Accuracy)、精确率(Precision)、召回率(Recall)和F1值作为评价指标。

### 1.6 模型训练环境

本研究计算平台 CPU 型号为 Intel Core i5 - 7300HQ, GPU 型号为 GeForce RTX 1050ti Laptop, RAM 容量 16 GB。采用 Python 3.9 编程语言, 使用 torch 1.12.0 + cu116 进行网络搭建、训练和测试。在参数设置方面, 模型训练设置批次大小为 200, 学习率为 0.0001。

## 2 结果与分析

### 2.1 不同模型分类结果

为选择奶牛粪便形态分类的最佳基础模型, 本研究分析对比 Swin Transformer 模型与 ResNet - 34<sup>[28]</sup>、MobileNet<sup>[29]</sup>、AlexNet<sup>[30]</sup> 及 ShuffleNet<sup>[31]</sup> 4 种经典分类网络的训练结果。图 7 为训练过程中 5 种模型的准确率变化曲线。可以看出, MobileNet 模型分类准确率最低, 平均准确率为 69.9%; AlexNet 和 ResNet - 34 模型随着训练批次准确率提升效果并不明显, 平均准确率分别为 72.9% 和 74.5%; Swin Transformer 模型和 ShuffleNet 模型准确率都在随训练批次的增加而增加, 最终平均准确率达到 94.7% 和 92.4%。Swin Transformer 模型与 ShuffleNet、ResNet - 34、AlexNet 和 MobileNet 模型相比准确率分别提高 2.3、20.2、21.8、24.8 个百分点。

表 3 为上述模型在测试集上的分类结果。可以看出, Swin Transformer 模型在测试集上分类准确率、精确率、召回率和 F1 值分别为 85.9%、85.8%、86.7% 和 86.2%。与 ShuffleNet、ResNet - 34、MobileNet 和 AlexNet 相比, Swin Transformer 准确率分别提高 1.8、4.0、12.8、23.4 个百分点, 精确率分别提高 9.3、3.8、13.4、22.3 个百分点, 召回率分别提高 7.8、3.8、11.3、15.7 个百分点, F1 值分别提高 8.5、3.8、12.3、19.2 个百分点。故本研究选取 Swin Transformer 作为基础网络开展奶牛粪便自动识别与分类研究。

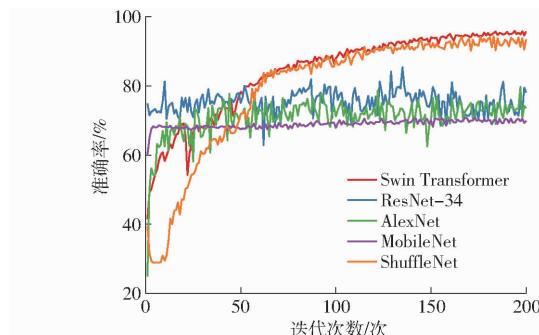


图 7 不同模型准确率变化曲线

Fig. 7 Accuracy curves of different models

表 3 5 种分类模型分类结果

Tab. 3 Classification results of five models %

模型	准确率	精确率	召回率	F1 值
Swin Transformer	85.9	85.8	86.7	86.2
ResNet - 34	81.9	82.0	82.9	82.4
MobileNet	73.1	72.4	75.4	73.9
AlexNet	62.5	63.5	71.0	67.0
ShuffleNet	84.1	76.5	78.9	77.7

### 2.2 模型改进前后分类结果

为评估模型改进效果, 分析对比 VGG - ST 模型与原 Swin Transformer 模型以及 VGG11 模型在相同测试集的实验结果, 如表 4 所示。由表 4 可知, VGG - ST 模型的总体识别准确率最高, 为 89.5%, 与原 Swin Transformer 模型以及 VGG11 模型相比, 分别提高 3.6、9.8 个百分点。VGG - ST 模型对稀便、软便和硬便的分类精确率最高, 相比 Swin Transformer 分别提高 9.3、0.3、5 个百分点。VGG -

表 4 3 种模型分类结果

Tab. 4 Classification results of three models

%

模型	精确率				召回率				总体识别 准确率
	稀便	软便	硬便	正常粪便	稀便	软便	硬便	正常粪便	
VGG11	77.1	70.1	93.5	75.6	96.1	61.9	92.1	72.0	79.7
Swin Transformer	81.3	86.4	92.0	83.3	96.7	70.2	98.4	81.6	85.9
VGG - ST	90.6	86.7	97.0	83.3	97.0	76.3	98.7	86.2	89.5

ST 模型对 4 种形态粪便分类的召回率分别为 97.0% (稀便)、76.3% (软便)、98.7% (硬便) 和 86.2% (正常粪便), 均高于其它模型。

VGG-ST 模型在测试集上生成的混淆矩阵如图 8 所示。可以看出 VGG-ST 模型将 36 幅软便图像误识别为正常粪便, 将 43 幅正常粪便图像误识别为软便, 可能是因为两种类别在纹理上具有一定相似度, 造成部分误识; VGG-ST 模型将 54 幅稀便图像误识别为软便, 可能是因为稀便图像较为分散, 软便图像通常出现粪便飞溅情况, 容易造成错误识别。虽然 VGG-ST 模型存在一定的误分类问题, 但是在

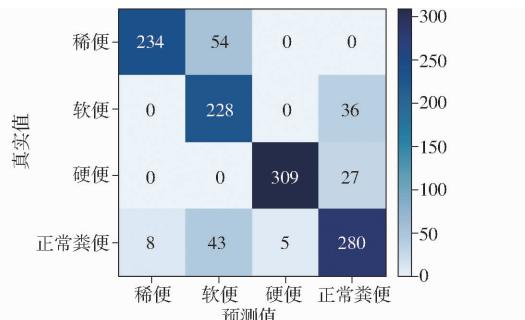


图 8 测试集混淆矩阵

Fig. 8 Confusion matrix of testing set

测试集整体分类准确率达 89.5%, 具有较好的分类性能。

### 2.3 粪便形态破坏对分类结果的影响

奶牛走动会造成奶牛粪便不同程度破坏, 对分类结果造成影响。根据图像中被破坏区域占粪便图像的百分比将粪便图像划分为: 轻度破坏(0~20%)、中度破坏(20%~40%)和重度破坏(40%以上)。为评估粪便形态破坏程度对分类结果的影响, 本研究分析对比 VGG-ST 模型与原 Swin Transformer 模型对不同破坏程度奶牛粪便图像分类结果, 如图 9 所示。图 9 分别为 2 种模型对轻度、中度、重度破坏粪便分类结果, 通过对比发现, VGG-ST 模型对轻度、中度破坏粪便图像分类置信度分别为 0.997 和 0.996, 均高于原 Swin Transformer 模型; 对重度破坏图像, VGG-ST 模型分类正确, 置信度为 0.998, 而 Swin Transformer 模型将正常粪便误分类为稀便。在本研究中, 测试集中共有 136 幅形状被破坏的奶牛粪便图像, 总体分类准确率达 88.5%。由此可知, VGG-ST 模型能够较好地识别出形状遭到破坏的粪便图像, 具有一定的抗干扰能力。

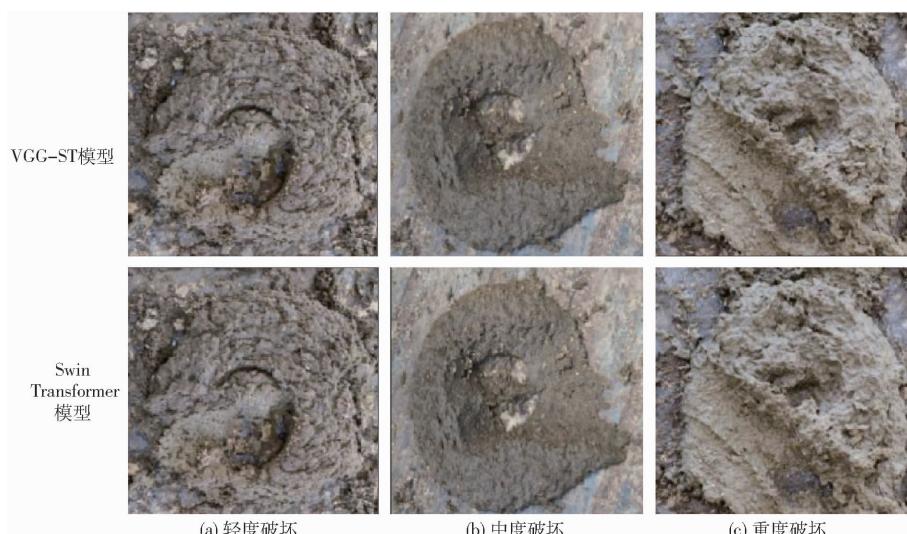


图 9 不同模型分类被破坏图像结果

Fig. 9 Classification results of damaged images by different models

## 3 结论

(1) 分析了 Swin Transformer、ResNet-34、ShuffleNet、MobileNet 和 AlexNet 5 种模型分类结果。结果表明, Swin Transformer 模型在测试集上分类准确率为 85.9%, 与 ShuffleNet、ResNet-34、MobileNet 和 AlexNet 模型相比分别提高 1.8、4.0、12.8、23.4 个百分

分点, 可作为奶牛粪便图像识别分类最优基础模型。

(2) 提出了基于 VGG-ST 模型的奶牛粪便形态分类方法, 在测试集上分类准确率达到 89.5%, 与 Swin Transformer 模型和 VGG11 模型相比提高 3.6、9.8 个百分点, 并且被破坏粪便的图像分类准确率达 88.5%, 具有一定的鲁棒性, 可为奶牛粪便形态自动筛查机器人研发提供方法参考。

## 参 考 文 献

- [1] 胡红莲, 于朝晖, 孙海洲, 等. 奶牛粪便检测试验[J]. 畜牧与饲料科学, 2006, 27(3):1~2.

- HU Honglian, YU Chaohui, SUN Haizhou, et al. Initial exploration of manure monitoring technique in dairy cattle [J]. Animal Husbandry and Feed Science, 2006, 27(3): 1–2. (in Chinese)
- [2] 郑国生, 施正香, 滕光辉. 基于不同行为时间的奶牛健康状况评价 [J]. 农业工程学报, 2019, 35(19): 238–244.
- ZHENG Guosheng, SHI Zhengxiang, TENG Guanghui. Health assessment of cows based on different behavior time [J]. Transactions of the CSAE, 2019, 35(19): 238–244. (in Chinese)
- [3] 赵晓静,高婕. 粪便分析技术在奶牛营养中的应用 [J]. 饲料博览, 2022(2): 51–55.
- ZHAO Xiaojing, GAO Jie. Application of analysis technology to feces in dairy cows [J]. Feed and Feeding, 2022(2): 51–55. (in Chinese)
- [4] 闻涛. 人体粪便图像中性状及颜色自动识别技术的研究 [D]. 成都:电子科技大学, 2021.
- WEN Tao. Research on automatic recognition technology of characters and colors in human stool images [D]. Chengdu: University of Electronic Science and Technology of China, 2021. (in Chinese)
- [5] HACHUEL D, JHA A, STALLER K, et al. Augmenting gastrointestinal health: a deep learning approach to human stool recognition and characterization in macroscopic images [J]. Gastroenterology, 2019, 156(6): 937.
- [6] WANG Jintao, SHEN Mingxia, LIU Longshen, et al. Recognition and classification of broiler droppings based on deep convolutional neural network [J]. Journal of Sensors, 2019, 2019: 1–10.
- [7] LIU Ze, LIN Yutong, CAO Yue, et al. Swin transformer: hierarchical vision transformer using shifted windows [C] // Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 10012–10022.
- [8] 许春陶,钱育蓉,范迎迎,等. 基于 CNN 与 Swin Transformer 的新疆荒漠植物识别研究 [J]. 微电子学与计算机, 2023(6): 33–41.
- XU Chuntao, QIAN Yurong, FAN Yingying, et al. Research on the identification of desert plants in Xinjiang based on CNN and Swin Transformer [J]. Microelectronics & Computer, 2023(6): 33–41. (in Chinese)
- [9] 刘拥民,刘翰林,石婷婷,等. 一种优化的 Swin Transformer 番茄叶片病害识别方法 [J]. 中国农业大学学报, 2023, 28(4): 80–90.
- LIU Yongmin, LIU Hanlin, SHI Tingting, et al. Tomato leaf disease recognition based on an optimized Swin Transformer [J]. Journal of China Agricultural University, 2023, 28(4): 80–90. (in Chinese)
- [10] 王璨,武新慧,张燕青,等. 基于移位窗口 Transformer 网络的玉米田间场景下杂草识别 [J]. 农业工程学报, 2022, 38(15): 133–142.
- WANG Can, WU Xinhui, ZHANG Yanqing, et al. Recognizing weeds in maize fields using shifted window Transformer network [J]. Transactions of the CSAE, 2022, 38(15): 133–142. (in Chinese)
- [11] 扶兰兰,黄昊,王恒,等. 基于 Swin Transformer 模型的玉米生长期分类 [J]. 农业工程学报, 2022, 38(14): 191–200.
- FU Lanlan, HUANG Hao, WANG Heng, et al. Classification of maize growth stages using the Swin Transformer model [J]. Transactions of the CSAE, 2022, 38(14): 191–200. (in Chinese)
- [12] 邱显焱,郭士超,王俊杰. 基于 Transformer 模型的干辣椒等级分类方法研究 [J]. 机电工程技术, 2023, 52(2): 34–37.
- QIU Xianyan, GUO Shichao, WANG Junjie. Study on grade classification method of dry chili based on Transformer model [J]. Mechanical & Electrical Engineering Technology, 2023, 52(2): 34–37. (in Chinese)
- [13] 江松,孔若男,李鹏程,等. 融合 Swin Transformer 与 CNN 的露天矿车前障碍物智能检测算法 [J]. 金属矿山, 2023(5): 228–236.
- JIANG Song, KONG Ruonan, LI Pengcheng, et al. Intelligent detection algorithm of obstacles in front of open-pit mine cars based on Swin Transformer and CNN [J]. Metal Mine, 2023(5): 228–236. (in Chinese)
- [14] 梁永勋,甄子洋,李苏宁,等. 基于 Transformer 模块和 CNN 的无人机避障方法研究 [J]. 机械与电子, 2023, 41(5): 56–61.
- LIANG Yongxun, ZHEN Ziyang, LI Suning, et al. Research on obstacle avoidance method of UAV based on Transformer module and CNN [J]. Machinery & Electronics, 2023, 41(5): 56–61. (in Chinese)
- [15] 谢光达,李洋,曲洪权,等. 基于改进 Transformer 的小目标车辆精确检测算法 [J]. 激光与光电子学进展, 2022, 59(18): 364–371.
- XIE Guangda, LI Yang, QU Hongquan, et al. Small target accurate vehicle detection algorithm based on improved Transformer [J]. Laser & Optoelectronics Progress, 2022, 59(18): 364–371. (in Chinese)
- [16] 徐天适,文莉,张华俊. 基于 Transformer 的车辆年款细粒度识别研究 [J]. 现代信息科技, 2023, 7(1): 75–79.
- XU Tianshi, WEN Li, ZHANG Huajun. Research on fine-grained recognition of vehicle model year based on Transformer [J]. Modern Information Technology, 2023, 7(1): 75–79. (in Chinese)
- [17] 熊海涛,林琪,宣魁,等. 基于改进 Faster R-CNN 的海参目标检测算法 [J]. 农业机械学报, 2022, 53(增刊2): 204–209.
- XIONG Haitao, LIN Qi, XUAN Kui, et al. Sea cucumber object detection algorithm based on improved Faster R-CNN [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(Supp. 2): 204–209. (in Chinese)
- [18] 李健源,柳春娜,卢晓春,等. 基于改进 YOLO v5s 和 TensorRT 部署的鱼道过鱼监测 [J]. 农业机械学报, 2022, 53(12): 314–322.
- LI Jianyuan, LIU Chunna, LU Xiaochun, et al. Fish passage monitoring based on improved YOLO v5s and TensorRT

- deployment [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(12) : 314 – 322. (in Chinese)
- [19] 蒋沛凡, 邓飞, 严星. 基于 Swin Transformer 特征提取的微地震初至拾取方法 [J]. 地球物理学进展, 2023, 38(3) : 1132 – 1142. JIANG Peifan, DENG Fei, YAN Xing. Microseismic first break picking based on Swin Transformer feature extraction [J]. Progress in Geophysics, 2023, 38(3) : 1132 – 1142. (in Chinese)
- [20] 张美娜, 王潇, 梁万杰, 等. 温室远程监控系统人机交互与番茄识别研究 [J]. 农业机械学报, 2022, 53(10) : 363 – 370. ZHANG Meina, WANG Xiao, LIANG Wanjie, et al. Human-computer interaction and tomato recognition in greenhouse remote monitoring system [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53 (10) : 363 – 370. (in Chinese)
- [21] 代晓林, 刘梦孜, 生群, 等. 基于改进 Swin Transformer 的钢板表面缺陷检测方法 [J]. 装备制造技术, 2022(4) : 88 – 91.
- [22] 田应仲, 卜雪虎. 基于注意力机制与 Swin Transformer 模型的腰椎图像分割方法 [J]. 计量与测试技术, 2021, 48(12) : 57 – 61. TIAN Yingzhong, BU Xuehu. Lumbar spine image segmentation method based on attention mechanism and Swin Transformer model [J]. Metrology & Measurement Technique, 2021, 48(12) : 57 – 61. (in Chinese)
- [23] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. arXiv Preprint, arXiv: 1409.1556, 2014.
- [24] 李建国, 高艳霞. 规模化生态奶牛养殖技术 [M]. 北京: 中国农业大学出版社, 2013.
- [25] 郭智超. 基于图像增强算法的低照度图像检测的研究 [D]. 桂林: 桂林电子科技大学, 2022. GUO Zhichao. Research on low illumination image detection based on image enhancement algorithm [ D ]. Guilin: Guilin University of Electronic Technology , 2022. (in Chinese)
- [26] 刘千顺. 数字图像去噪、锐化与颜色增强研究 [D]. 杭州: 浙江大学, 2016. LIU Qianshun. Research on denoising, sharpening and color enhancement about digitallmage enhancement [ D ]. Hangzhou: Zhejiang University , 2016. (in Chinese)
- [27] 刘昱垚. 基于 Gamma 校正的图像对比度增强方法研究 [D]. 呼和浩特: 内蒙古工业大学, 2021. LIU Yuyao. Research on image contrast enhancement method based on Gamma correction [ D ]. Huhhot: Inner Mongolia University of Technology, 2021. (in Chinese)
- [28] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition [ C ] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770 – 778.
- [29] HOWARD A G, ZHU Menglong, CHEN Bo, et al. MobileNets: efficient convolutional neural networks for mobile vision applications [J]. arXiv Preprint, arXiv: 1704.04861, 2017.
- [30] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [ J ]. Advances in Neural Information Processing Systems, 2012, 25(2) : 1097 – 1105.
- [31] MA N, ZHANG X, ZHENG H, et al. ShuffleNet V2: practical guidelines for efficient CNN architecture design [ C ] // Proceedings of the European Conference on Computer Vision (ECCV), 2018: 116 – 131.