

基于改进 VGGNet 的羊个体疼痛识别方法

韩 丁^{1,2} 王 斌² 王 亮^{2,3} 侯越诚² 田虎强² 张世龙²

(1. 内蒙古大学草原家畜生殖调控与繁育国家重点实验室, 呼和浩特 010030;
2. 内蒙古大学电子信息工程学院, 呼和浩特 010021; 3. 复旦大学信息科学与工程学院, 上海 200433)

摘要: 针对目前人工识别羊个体疼痛过程中存在的经验要求高、识别准确率低、消耗成本高、延误疾病治疗等问题, 引入当前主流图像分类网络 VGGNet(Visual geometry group network)对有疼痛和无疼痛的羊脸表情进行识别, 提出一种基于改进 VGGNet 的羊脸痛苦表情识别算法, 改进后的网络为 STVGGNet(Spatial transformer visual geometry group network)。该算法将空间变换网络引入 VGGNet, 通过空间变换网络增强对羊脸痛苦表情特征区域的关注程度, 提高对羊脸痛苦表情的识别准确率。本文对原有的羊脸表情数据集进行了扩充, 新增 887 幅羊脸表情图像。但是新的数据集图像数量仍然较少, 所以本文利用 ImageNet 数据集进行迁移学习, 微调后用来自动分类有痛苦和无痛苦的羊脸表情。对羊面部表情数据集的实验结果表明, 使用 STVGGNet 实现的最佳训练准确率为 99.95%, 最佳验证准确率为 96.06%, 分别比 VGGNet 高 0.15、0.99 个百分点。因此, 本文采用的模型在羊脸痛苦表情识别中有非常好的识别效果并且具有较强的鲁棒性, 为畜牧业中羊的疾病检测智能化发展提供了技术支撑。

关键词: 羊脸表情; 疼痛识别; 深度学习; 改进 VGGNet; 羊脸数据集

中图分类号: TP391.41 文献标识码: A 文章编号: 1000-1298(2022)06-0311-07

OSID: 

Individual Pain Recognition Method of Sheep Based on Improved VGGNet

HAN Ding^{1,2} WANG Bin² WANG Liang^{2,3} HOU Yuecheng² TIAN Huqiang² ZHANG Shilong²

(1. State Key Laboratory of Reproductive Regulation and Breeding of Grassland Livestock,
Inner Mongolia University, Huhhot 010030, China

2. College of Electronic Information Engineering, Inner Mongolia University, Huhhot 010021, China

3. School of Information Science and Technology, Fudan University, Shanghai 200433, China)

Abstract: In order to solve the problems with manual assessment of individual sheep's pain, which includes the requirement for a high level of human experience on the subject matter, a lack of pain recognition accuracy, and extended delay for the treatment for sheep, spatial transformer visual geometry group network (STVGGNet) was proposed as an improved model to the current mainstream deep learning model visual geometry group network (VGGNet). The STVGGNet algorithm introduced the spatial transformer networks and increased the area of analysis and in return improved the level of recognition of a sheep's facial expression with regards of pain. Additional 887 images were added to the pre-existing dataset of sheep's facial expression images. However, because the new image dataset remained low in quantity, the model also utilized ImageNet for transfer learning and fine-tuning classification between painful and non-painful sheep's facial expressions. The experimental results showed that the best performance accuracy of STVGGNet in training stood at 99.95% with the best validation results upwards of 99.06% vs the VGGNet model which yielded 99.80% and 95.07% respectively. Therefore, with STVGGNet's improved accuracy and strong robustness to classify pain within a sheep's facial expression, it provided technical support for the intelligent development of sheep disease detection in animal husbandry.

Key words: face expression of sheep; pain recognition; deep learning; improved VGGNet; sheep face dataset

0 引言

在羊养殖业中,羊的疼痛往往是由疾病引起的,所以疼痛检测对羊的福利化养殖和健康生长非常重要,而找到快速、准确的疼痛检测方法成为关键^[1-2]。LANGFORD 等^[3]最早对动物面部疼痛识别进行了研究。对于羊的疼痛,2009 年 STUBSJØEN 等^[4]利用红外热成像法(Infrared thermography, IRT) 和心率变化法(Heart rate variability, HRV) 检测眼睛温度变化和心率变化来进行识别,但是以上方法检测速度较慢并且需要耗费大量人力。由于疼痛往往会导致羊的面部表情发生变化,所以在 2016 年,一种人工评估羊疼痛的标准方法——羊表情疼痛量表(Sheep pain facial expression scale, SPFES) 被提出,这是一种利用羊的面部表情来检测羊疼痛的标准方法,该方法根据耳旋程度、鼻孔形状、眼睛的收缩程度等对每个区域可能存在的疼痛进行单独评分,例如眼睛完全睁开表示没有痛苦记为 0 分,半闭合表示可能存在痛苦记为 1 分,几乎完全闭合表示存在痛苦的可能性较大记为 2 分,然后将眼窝、脸颊、耳朵、唇颤、鼻子 5 个区域的评分相加,如果大于 1.5 分,则认为该羊存在痛苦,这种方法已被证明能够高准确性地识别羊的面部疼痛^[5]。SPFES 的提出证明了利用羊面部表情检测疼痛是可行的,但是评分人员需要经过专业的培训,而且可能会存在个体间标准的差异,这种对疼痛评分的人工检测方法还存在时间长和效率低的问题。

计算机视觉技术在人脸识别、疾病诊断等领域得到了非常好的应用效果^[6-8]。在牧场养殖中,计算机视觉技术也能解决许多相关问题^[9-10]。在 2020 年,NOOR 等^[11]利用计算机视觉技术,提出了基于迁移学习的羊痛苦表情自动分类方法,将羊脸图像作为输入,训练了深度学习模型。数据集图像中具有复杂的背景环境,但是羊的痛苦表情仅与部分面部特征有关。因此卷积神经网络会提取到许多无关的特征,对识别的准确率产生影响。在实际的畜牧养殖业中,牧场的养殖规模较大,微小的识别错误也会导致牧场的管理秩序产生混乱,因此提升识别的准确率意义重大。然而 NOOR 等的方法并未将与痛苦无关的面部特征去除或者减弱无关面部特征对分类准确率的影响。

本文在 VGGNet(Visual geometry group network) 中引入空间变换网络(Spatial transformer nets, STN) 组成 STVGGNet, 提高对具有复杂背景的羊脸痛苦表情图像的识别准确率。针对羊脸表情数据集中图像较少的问题,对羊脸表情数据集进行扩充。利用

从牧场和网络上采集的羊脸痛苦表情的真实图像对训练好的检测模型进行评价。

1 材料和方法

1.1 数据集与预处理

为了将三线插值特征法(Triplet interpolated features, TIF) 引入羊脸识别中,YANG 等^[12]制作了一个包含 600 幅羊脸图像的数据集,手动标记了羊脸的边界框和特征点,该羊脸数据集没有包含表情标签,随后 LU 等^[13]为该数据集添加了相应的表情标签。2020 年,NOOR 等开发了一个高分辨率的羊脸数据集,其中羊脸图像来自于 ImageNet、NADIS、Pixabay、Flickr 和 Gettyimages 等不同的网站。在该数据集中,无痛苦的羊脸表情图像被称为正常羊脸图像,具有痛苦的羊脸表情图像被称为异常羊脸图像。该数据集按照 SPFES 标准将 2 350 幅图像划分为 1 407 幅图像组成的正常羊脸数据集和 943 幅图像组成的异常羊脸数据集。

本文制作了一个符合 SPFES 标准的新数据集。SPFES 定义的羊面部疼痛特征与耳朵、鼻子、眼睛有关。对于耳朵,SPFES 定义了羊脸部正面和侧面耳朵旋转代表的疼痛程度,耳廓可见、部分可见和不可见分别代表没有疼痛、低痛和高痛。对于鼻子,用鼻孔的形状定义了疼痛程度,“U”形鼻孔代表没有疼痛,“V”形鼻孔代表有痛。对于眼睛,完全睁开表示没有疼痛,而半闭则有疼痛。本文数据集在 NOOR 等提出的 989 幅正常图像和 154 幅异常图像组成的部分数据集基础上,增加了 887 幅图像,其中 435 幅新增图像来自 Pixabay、VCG、VEER 和百度网站,其余 452 幅新增图像为牧场实地拍摄图像,数据采集地为内蒙古自治区鄂尔多斯市鄂托克旗亿维养殖基地。数据采集装备为佳能 PowerShot - G7 - X - Mark II 型相机,分辨率为 2 400 像素 × 1 600 像素。数据采集对象为阿尔巴斯绒山羊,数量为 226 只,其中成年公羊 56 只,幼龄断奶公羊 20 只,成年母羊 125 只,幼龄断奶母羊 25 只,每只羊选择拍摄效果较好的 2 幅为数据集图像。本文将收集的图像按照 SPFES 标准进行了评分和分类,评分结果如表 1 所示,评分小于 1.5 分的图像总计 841 幅,为正常羊脸图像,评分大于 1.5 分的图像总计 46 幅为异常羊脸图像。新的数据集一共由 2 030 幅图像组成,其中正常羊脸图像 1 830 幅,异常羊脸图像 200 幅。图 1

表 1 新增羊脸图像评分结果

Tab. 1 Score results of new sheep face images

评分分数/分	0	1	2	3	4	5	6	7	8	9	10
数量/幅	726	115	8	17	11	5	4	1	0	0	0



图 1 羊脸数据集部分图像示例

Fig. 1 Partial images of sheep face dataset

为本文数据集部分图像。

本文虽然对羊脸表情数据集进行了扩充,但是数据集的尺寸依然较小,存在过拟合的可能。过拟合是指模型将训练数据集中的采样误差,作为数据之间的差异进行拟合,从而导致模型在训练数据集中的训练误差很低,而在测试数据集中的测试误差很高(或者说泛化误差高)^[14]。通常可以使用数据增强的方法扩充训练数据,以减少过拟合问题,增加泛化性能^[15]。本文数据增强操作有随机旋转、随机翻转、裁剪。样本图像的数量扩充为原来的4倍,即8120幅羊脸图像。

1.2 STVGGNet 结构分析

1.2.1 STVGGNet 构建动机

在真实牧场环境中,通常使用固定位置的摄像头采集羊脸图像,采集到的图像中包含了许多与羊脸痛苦表情无关的特征,大幅降低了羊脸痛苦表情识别的准确率^[16]。而羊脸痛苦表情仅与部分脸部特征有关,需要开发一种能够重点关注与羊脸痛苦表情相关特征区域的模型来提高准确率。因此,本文将空间变换网络加入 VGGNet 来提高识别羊脸痛苦表情的准确率。

1.2.2 实现细节和体系结构可视化

VGGNet 由卷积层、池化层和全连接层组成,根据不同的组合方式和网络深度,有多种不同的网络配置^[17],本研究选择其中4种作为基础网络。本文依据研究所需的输入尺寸,对 VGGNet 的网络结构参数进行了优化,如图2所示。

在 VGGNet 的卷积层前加入了空间变换网络。空间变换网络可以在进行图像分类之前先学习到分类对象的特征所在区域,并通过旋转、平移、裁剪等方法生成一个新的图像,然后将新生成的图像作为分类网络的输入。该方法在 MNIST 手写数据集和街景门牌号数据集(Street view house numbers, SVHN)上被证明有很好的效果^[18],本文将空间变换

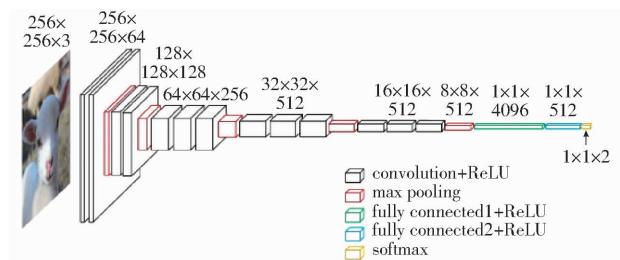


图 2 VGG 网络结构

Fig. 2 VGG network structure

网络作为羊脸表情相关面部特征区域提取器,提取到的区域图将取代原始图像作为羊脸表情分类网络的输入。空间变换网络整体结构如图3所示,包含定位网络、网格生成器、采样器3部分。

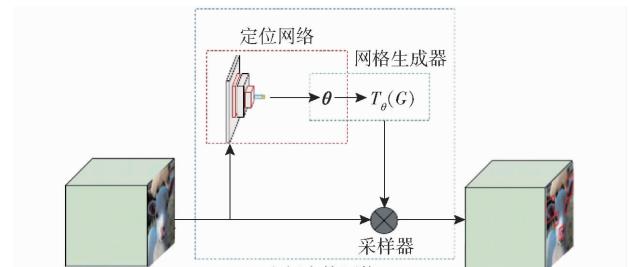


图 3 空间变换网络

Fig. 3 Spatial transformer network

定位网络从输入到输出的变换公式为

$$\theta = f_{T_\theta}(U) \quad (1)$$

式中 f_{T_θ} —卷积函数

θ —仿射变换矩阵

U —经过数据增强的羊脸图像

f_{T_θ} 是一个卷积神经网络,用于学习仿射变换矩阵,由2个卷积层、2个最大池化层和2个全连接层组成,一个卷积层使用的卷积核尺寸为 8×8 ,另一个卷积层的卷积核尺寸为 7×7 。定位网络并不是直接从数据集学习如何转换,而是嵌入在图像分类网络中,根据分类网络的损失最小化原则自动学习仿射变换矩阵参数 θ 。

根据由定位网络得到的仿射变换矩阵 θ ,生成

一个输入图像和转换图像之间的坐标对照网格。网格生成器生成的转换公式为

$$\begin{bmatrix} x'_i \\ y'_i \\ 1 \end{bmatrix} = \boldsymbol{\theta} \begin{bmatrix} x_i^s \\ y_i^s \\ 1 \end{bmatrix} = \begin{bmatrix} \theta_{11} & \theta_{12} & \theta_{13} \\ \theta_{21} & \theta_{22} & \theta_{23} \end{bmatrix} \begin{bmatrix} x_i^s \\ y_i^s \\ 1 \end{bmatrix} \quad (2)$$

式中 x'_i ——像素点 p_i^t 的横坐标

y'_i ——像素点 p_i^t 的纵坐标

x_i^s ——像素点 p_i^s 的横坐标

y_i^s ——像素点 p_i^s 的纵坐标

将输入图像按网格的坐标对照关系,转换为一个新图像,转发给分类网络,网格转换图如图 4 所示。STVGGNet 的识别过程如图 5 所示。VGGNet 与 STVGGNet 的参数数量如表 2 所示,本文提出的 STVGGNet 与 VGGNet 相比,参数数量并没有明显的增加。

2 实验与结果分析

2.1 实验配置

本文实验使用的开发平台为 Windows 10, GPU 为 NVIDIA Quadro RTX6000, 深度学习框架为 Pytorch1.6。进行了多次实验之后选择如下参数: 优化方法为随机梯度下降(SGD)算法, 动量为 0.9, 初始学习率为 0.01, 迭代周期(Epoch)为 50。

表 2 参数所占内存
Tab. 2 Memory occupied by parameter

网络	VGG11	STVGG11	VGG13	STVGG13	VGG16	STVGG16	VGG19	STVGG19
输入尺寸	$256 \times 256 \times 3$							
参数所占内存/MB	114.1	114.9	114.3	115.1	119.6	120.4	124.9	125.7

2.2 迁移学习

在计算机视觉应用领域中,为了达到很好的识别效果,需要很大的数据集,但是大型数据集制作成本非常高,另外从头训练需要非常高的计算性能。使用迁移学习可以满足大型数据集和高计算性能的两大需求,在训练过程中快速地获得较好的识别效果^[19~20]。新制作的羊脸表情数据集属于小型数据集,直接进行训练不能达到很好的训练效果,故本文使用迁移学习对所有涉及的网络进行预训练。本文使用 ImageNet 数据集对 VGGNet 和 STVGGNet 进行预训练,然后对于 VGGNet 预训练模型,冻结全部的卷积层,使用羊脸数据集训练剩余的 3 个全连接层; 对于 STVGGNet 预训练模型,也冻结全部的卷积层,使用羊脸数据集训练剩余的空间变换网络和 3 个全连接层。

2.3 实验结果

在本研究中,将数据集的 70% 用于训练,20%

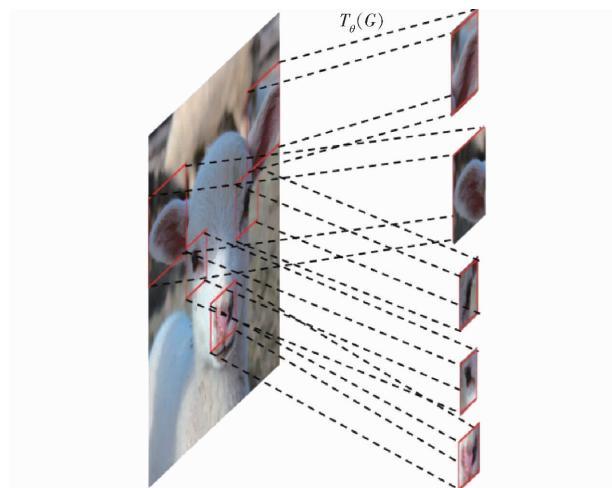


图 4 网格转换图

Fig. 4 Grid transformation diagram

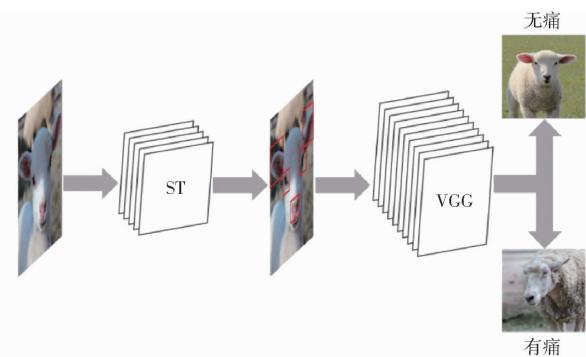


图 5 STVGGNet 识别过程

Fig. 5 STVGGNet identification process

用于验证,10% 用于测试评估 VGGNet 和 1.2.2 节中提出的 STVGGNet。VGGNet 和 STVGGNet 的分类结果如表 3 所示。图 6 为在羊脸数据集上对 VGGNet 和 STVGGNet 进行训练时的损失值。从表 3 中可以看出,VGGNet 中 VGG19 的训练准确率

表 3 网络训练准确率、训练时间、验证准确率
Tab. 3 Training accuracy, training time and validation accuracy of networks

网络	训练准确率/%	训练时间/s	验证准确率/%
VGG11	99.16	697	93.60
STVGG11	99.22	729	94.58
VGG13	99.21	899	94.09
STVGG13	99.65	1 016	94.58
VGG16	99.56	988	95.07
STVGG16	99.70	1 025	95.57
VGG19	99.80	1 060	95.07
STVGG19	99.95	1 104	96.06

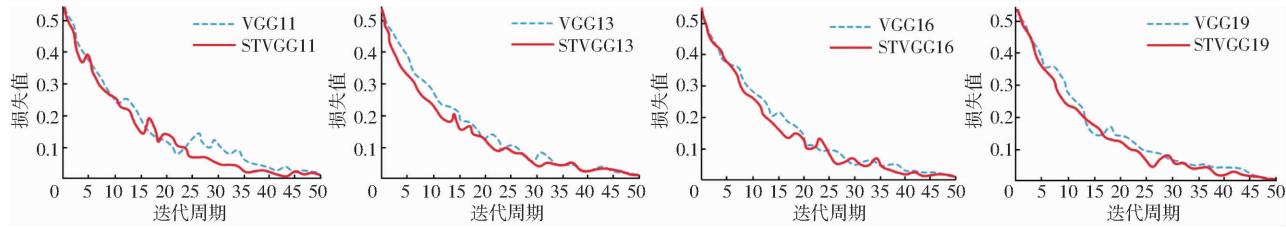


图 6 不同网络的训练损失值变化曲线

Fig. 6 Variation curves of training loss value of different networks

最高,达到了 99.80%,而 STVGGNet 中训练准确率最高的是 STVGG19,达到了 99.95%,比 VGG19 高 0.15 个百分点。并且 STVGGNet 的训练准确率均比 VGGNet 中对应的网络高,最多高 0.44 个百分点,最少高 0.06 个百分点。

采用 STVGGNet 能够提高训练的准确率,却导致其相较于 VGGNet 的参数数量有所增加。参数数量上升会导致训练时间的增加。虽然 STVGGNet 与 VGGNet 相比训练时间均有所增加,但 STVGGNet 用较短的时间增加量换取训练准确率的提升是值得的。

STVGGNet 的验证准确率得到了明显提升。如表 3 所示,STVGG19 的验证准确率提升最多,相比于 VGG19 提升了 0.99 个百分点。STVGG13 的提升最少,相比于 VGG13 也提升了 0.49 个百分点。验证准确率的提升证明了 STVGGNet 的泛化性能优于 VGGNet。

本文对改进后的 STVGGNet 与 VGGNet 在羊脸痛苦表情识别中的表现进行定量评估时,使用混淆矩阵(Confusion matrix)、准确率(Accuracy)、错误率(Error rate)、精确度(Precision)、召回率(Recall)、

F1 值(F1 score)来评估两种模型。两种模型的测试结果混淆矩阵如图 7 所示。本文预测了两种可能的类别,分别为正常(没有痛苦)羊脸和异常(有不同程度的痛苦)羊脸。分类器测试了 812 幅图像,其中 732 幅没有疼痛,80 幅有不同程度的疼痛。统计了分类实验数据的真正样本(True positive, TP)和真负样本(True negative, TN)的数量。此外,也统计了预测出的假正样本(False positive, FP)和假负样本(False negative, FN)数量。VGG19 的测试结果中真正样本和真负样本分别有 704 幅和 72 幅,假正样本和假负样本分别有 8 幅和 28 幅,而改进后泛化性能最好的 STVGG19 的预测结果中真正样本和真负样本分别有 732 幅和 76 幅,假正样本和假负样本分别有 4 幅和 28 幅。图 8 展示了两种模型的部分预测结果。

所有模型对测试集预测的准确率、错误率、精确度、召回率、F1 值如表 4 所示。评估结果表明,在羊脸痛苦表情分类测试任务中,除了 STVGG16 与 VGG16 的测试准确率相同以外,STVGGNet 的测试准确率均高于对应的 VGGNet,且所有的 STVGGNet 的 F1 值均高于对应的 VGGNet。从整体上看,

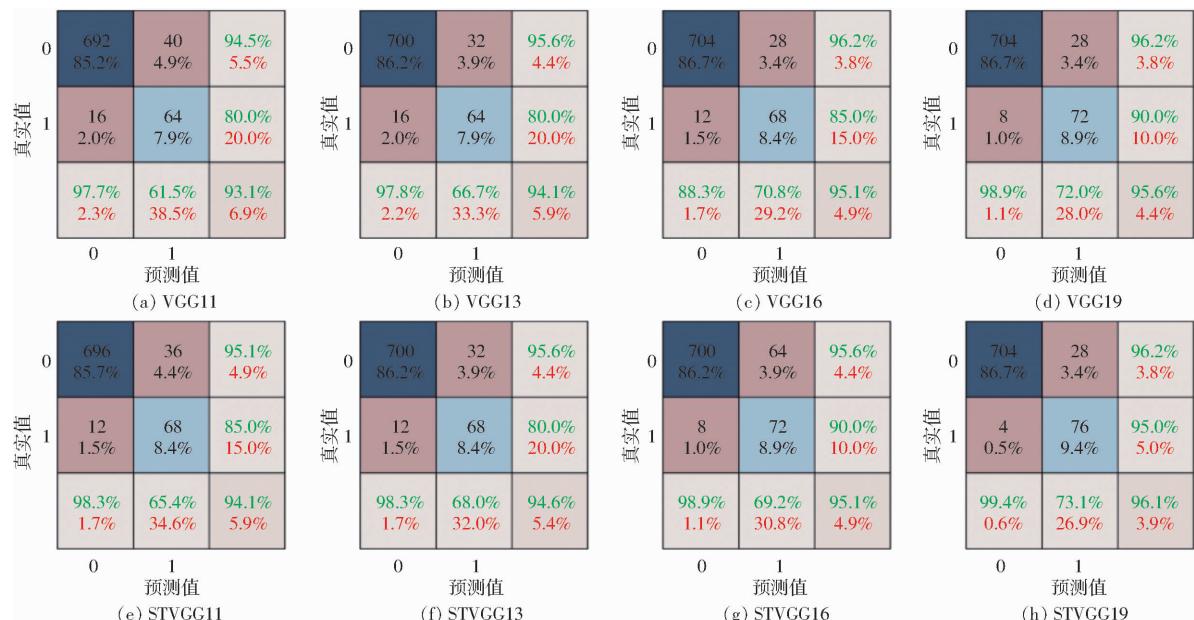


图 7 混淆矩阵图

Fig. 7 Confusion matrix



图 8 预测结果示例

Fig. 8 Example of prediction results

表 4 准确率、错误率、精确度、召回率、F1 值

Tab. 4 Accuracy, error rate, precision, recall
and F1 value

网络	准确率	错误率	精确度	召回率	F1 值	%
VGG11	93.10	6.90	94.54	97.74	96.11	
STVGG11	94.09	5.91	95.08	98.31	96.67	
VGG13	94.09	5.91	95.63	97.77	96.69	
STVGG13	94.58	5.42	95.63	98.31	96.95	
VGG16	95.07	4.93	96.17	98.32	96.96	
STVGG16	95.07	4.93	95.63	98.87	97.22	
VGG19	95.57	4.43	96.17	98.88	97.51	
STVGG19	96.06	3.94	96.17	99.44	97.78	

STVGGNet 的分类性能要优于 VGGNet。对于分类性能最好的 STVGG19 和对应的 VGG19, 虽然 STVGG19 的训练准确率仅比 VGG19 高 0.15 个百分点(表 3),但是 STVGG19 模型的预测准确率高于 VGG19 模型 0.49 个百分点(表 4),这说明与 VGG19 模型相比,STVGG19 的泛化性能更好。

2.4 羊个体姿态与年龄段对识别效果的影响

为探究羊个体姿态对识别效果的影响,从数据集中成年羊站立姿态下提取的羊面部图像和躺卧姿态下提取的羊面部图像中随机抽取各 30 幅面部图像,总计 60 幅图像。使用 VGG19 和 STVGG19 对站姿、卧姿和混合状态 3 种情况各进行了 10 次测试,得到的平均测试准确率如表 5 所示。

表 5 站姿、卧姿和混合姿态的平均测试准确率

Tab. 5 Average accuracy of standing, lying and mixed posture

模型	站姿	卧姿	混合状态	%
VGG19	95.63	95.46	95.55	
STVGG19	96.27	95.83	96.06	

由表 5 可知,网络对站姿和卧姿时羊面部疼痛均有较好的识别效果,且站姿的识别准确率略高于卧姿。

为探究羊年龄段对识别效果的影响,从数据集中站立姿态下幼龄断奶羊提取的面部图像和成年羊提取的羊面部图像中随机抽取各 30 幅面部图像,总计 60 幅图像。使用 VGG19 和 STVGG19 对幼龄、成年和混合年龄 3 种情况各进行了 10 次测试,得到的平均测试准确率如表 6 所示。

表 6 幼龄、成年和混合年龄的平均测试准确率

Tab. 6 Average accuracy of young, adult and mixed age

模型	幼龄	成年	混合年龄	%
VGG19	95.53	95.49	95.55	
STVGG19	96.13	96.06	96.16	

由表 6 可知,模型对幼龄羊和成年羊面部疼痛均有较好的识别效果,而且不同年龄段的测试结果没有明显区别。

3 结论

(1)为了提高识别模型的准确率,将空间变换网络引入羊脸痛苦表情识别中,提出了 STVGGNet,该模型先提取羊脸痛苦表情的相关感官特征区域,再进行分类,降低了复杂环境和痛苦表情无关的面部特征对识别效果的影响。

(2)针对羊脸表情数据集不足的问题,收集了 887 幅羊脸图像来扩充原有的数据集,通过 SPFES 方法将图像分为 841 幅正常羊脸图像和 46 幅异常羊脸图像。在羊脸表情数据集上使用迁移学习和微调的方法训练 STVGGNet,并进行了测试。STVGGNet 获得的最佳训练和验证的效果为

99.95% 和 96.06%, 比 VGGNet 分别高 0.15、0.99 个百分点, 并且定量评估表明, STVGGNet 中表现最好的 STVGG19 相比于 VGGNet 中表现最好的 VGG19, 除精确度相同外, 召回率和 F1 值均高于

VGG19, STVGG19 在实际应用场景中性能更好。对于不同姿态和不同年龄段的羊脸图像均有较好的识别效果, 站姿提取的羊面部表情识别准确率略高于卧姿, 不同年龄段识别效果基本无差异。

参 考 文 献

- [1] SHRIVER A. The asymmetrical contributions of pleasure and pain to animal welfare [J]. Cambridge Quarterly of Healthcare Ethics, 2014, 23(2):152–162.
- [2] LARRONDO C, BUSTAMANTE H, GALLO C. Sheep farmers' perception of welfare and pain associated with routine husbandry practices in Chile [J]. Animals, 2018, 8(12):197–210.
- [3] LANGFORD D J, BAILEY A L, CHANDA M L, et al. Coding of facial expressions of pain in the laboratory mouse [J]. Nature Methods, 2010, 7(6):447–449.
- [4] STUBSJØEN S M, FLØ A S, MOE R O, et al. Exploring non-invasive methods to assess pain in sheep [J]. Physiology & Behavior, 2009, 98(5):640–648.
- [5] MCLENNAN K M, REBELO C, CORKE M J, et al. Development of a facial expression scale using footrot and mastitis as models of pain in sheep [J]. Applied Animal Behaviour Science, 2016, 176:19–26.
- [6] PHAWINEE S, CAI J F, GUO Z Y, et al. Face recognition in an intelligent door lock with ResNet model based on deep learning [J]. Journal of Intelligent and Fuzzy Systems, 2021, 40(4):1–11.
- [7] MARITZA B L, GINER A H, LUIS S, et al. EduRecomSys: an educational resource recommender system based on collaborative filtering and emotion detection [J]. Interacting with Computers, 2020, 32(4):407–432.
- [8] SARKAR R, HAZRA A, SADHU K, et al. A novel method for pneumonia diagnosis from chest X-Ray images using deep residual learning with separable convolutional networks [C] // Computer Vision and Machine Intelligence in Medical Image Analysis. Singapore: Springer, 2020:1–12.
- [9] 王少华, 何东健, 刘冬. 基于机器视觉的奶牛发情行为自动识别方法 [J]. 农业机械学报, 2020, 51(4):241–249.
WANG Shaohua, HE Dongjian, LIU Dong. Automatic recognition method of dairy cow estrus behavior based on machine vision [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(4):241–249. (in Chinese)
- [10] 何东健, 刘建敏, 熊虹婷, 等. 基于改进 YOLO v3 模型的挤奶奶牛个体识别方法 [J]. 农业机械学报, 2020, 51(4):250–260.
HE Dongjian, LIU Jianmin, XIONG Hongting, et al. Individual identification of dairy cows based on improved YOLO v3 [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(4):250–260. (in Chinese)
- [11] NOOR A, ZHAO Y, KOUBAA A, et al. Automated sheep facial expression classification using deep transfer learning [J]. Computers and Electronics in Agriculture, 2020, 175:105528.
- [12] YANG H, ZHANG R, ROBINSON P. Human and sheep facial landmarks localisation by triplet interpolated features [C] // IEEE Winter Conference on Applications of Computer Vision, 2016.
- [13] LU Y, MAHMOUD M, ROBINSON P. Estimating sheep pain level using facial action unit detection [C] // IEEE International Conference on Automatic Face and Gesture Recognition, 2017.
- [14] KRIZHEVSKY A, SUTSKEVER I, HINTON G E, et al. ImageNet classification with deep convolutional neural networks [C] // Neural Information Processing Systems, 2012: 1097–1105.
- [15] ZOPH B, CUBUK E D, GHIASI G, et al. Learning data augmentation strategies for object detection [C] // European Conference on Computer Vision, 2020.
- [16] JWADE S A, GUZZOMI A, MIAN A. On farm automatic sheep breed classification using deep learning [J]. Computers and Electronics in Agriculture, 2019, 167:105055.
- [17] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [C] // International Conference on Learning Representations, 2015.
- [18] JADERBERG M, SIMONYAN K, ZISSERMAN A, et al. Spatial transformer networks [C] // Advances in Neural Information Processing Systems, 2015: 2017–2025.
- [19] PAN S J, TSANG I W, KWOK J T, et al. Domain adaptation via transfer component analysis [J]. IEEE Transactions on Neural Networks, 2011, 22(2):199–210.
- [20] 许景辉, 邵明烨, 王一琛, 等. 基于迁移学习的卷积神经网络玉米病害图像识别 [J]. 农业机械学报, 2020, 51(2):230–236, 253.
XU Jinghui, SHAO Mingye, WANG Yichen, et al. Recognition of corn leaf spot and rust based on transfer learning with convolution neural network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2):230–236, 253. (in Chinese)