

DOI:10.19651/j.cnki.emt.2314109

# 基于改进 Mask R-CNN 的牛脸目标检测算法<sup>\*</sup>

关忠榜 杨颜博 李敏超

(内蒙古科技大学信息工程学院 包头 014010)

**摘要:** 针对牛脸检测时,存在的检测精度不高、牛脸较小被漏检或误检等问题,提出一种改进的 Mask R-CNN + MResNet 模型。首先,在 ResNet101 网络的基础上提出一种 MResNet 网络,通过对 ResNet101 网络的改进,提高了模型检测精度。其次,对模型的 RPN 网络的锚框尺寸进行调整,提高了模型对较小目标的牛脸检测能力。实验结果表明,MResNet 网络对牛脸检测精度相比较原始的网络模型,提高了 12.6%;改进后的模型对于小目标检测能力平均精度较原始模型提高了 2.4%。说明该模型能有效的实现小目标牛脸的检测,具有实际应用价值。

**关键词:** 牛脸检测;Mask R-CNN 模型;ResNet101 网络;RPN 网络

中图分类号: TP391 文献标识码: A 国家标准学科分类代码: 230

## Bull face target detection algorithm based on improved Mask R-CNN

Guan Zhongbang Yang Yanbo Li Minchao

(College of Information Engineering, Inner Mongolia University of Science and Technology, Baotou 014010, China)

**Abstract:** To address issues such as low detection accuracy and the occurrence of missing or misidentifying bovine faces due to their small size, we propose an enhanced model called Mask R-CNN + MResNet. Firstly, we introduce a MResNet network based on the ResNet101 architecture, which enhances the detection accuracy of the model by improving upon ResNet101. Secondly, we adjust the anchor frame size of the model's RPN network to enhance its capability in detecting small targets. Experimental results demonstrate that compared to the original network model, MResNet achieves a 12.6% improvement in bovine face detection accuracy. Furthermore, the improved model exhibits a 2.4% increase in average accuracy for detecting small targets, compared to the original model. These results indicate that this model effectively detects small target cow faces and holds practical application value.

**Keywords:** bull face detection; Mask R-CNN model; ResNet101 network; RPN network

## 0 引言

随着计算机视觉技术的高速发展,动物脸部的检测也得到了人们的广泛关注。其中,牛的面部检测也成为近年来备受重视的研究课题之一。

目前,在进行牛脸检测时,采用深度学习技术成为了计算机视觉领域的热门技术。这项技术对于从事畜牧业领域的人员可以显著提高工作效率;同时,对于动物自身来说,这种方法也是提升动物福利的有效途径。宋肖肖等人主要关注了牛脸部的面部特征,并且为后续的检测和识别提供了基础<sup>[1]</sup>。但是该方法如果将神经网络算法应用到牛面部的轮廓提取中,将会获得更精确的定位和更短的耗时。汪文华通过应用经典的目标检测算法 YOLO 来确定牛的身份信息<sup>[2]</sup>。该研究选择目标检测算法时没有考虑到适合奶

牛个体身份识别的网络结构,从而提高系统识别准确率。而刘爽主要集中在对牛脸对象的检测上,通过改进的 VGG 网络(visual geometry group, VGG)以及独立设计的网络模型取得了显著的成果<sup>[3]</sup>。张晨鹏选择牛脸检测性能最优的 Faster R-CNN 目标检测算法来构建牛脸检测模型<sup>[4]</sup>。在此基础上,特征提取网络采用残差网络 50 (residual network 50, ResNet50) 替换 VGG16 网络(visual geometry group 16),增强模型的特征提取能力。姜世奇基于 YOLOv3 网络(you only look once version3)的基础上加以改进,在建立的牛脸部检测数据集上训练目标检测模型,最终表明该方法在牧场环境下可有效进行个体识别,对于智能化管牧场具有重要影响<sup>[5]</sup>。杨梅等<sup>[6]</sup>通过 Yolov5 网络(you only look once version5)完成牛脸检测,以 Inception\_

收稿日期:2023-07-14

\* 基金项目:内蒙古自治区自然科学基金委联合项目(2020LH06006)、内蒙古自治区科技厅(2019ZD025)、内蒙古教育厅(0406082219)、内蒙古包头市昆区科技局科技计划(YF2021011)、内蒙古自然科学基金(2021MS06007)、科技兴蒙行动重点专项(XM2021BT12)资助

Resnet\_v1 作为网络模型完成对牛脸特征提取,结果表明该模型对牛脸检测具有较高准确率,为牛脸特征提取奠定了基础。目前进行牛脸的目标检测时仍然存在一些问题,例如检测精度不高、较小的目标容易被漏检或误检等。

为了解决上述问题,本文提出了一种改进的 Mask R-CNN 模型,选择基于 MResNet 网络(Modified ResNet101)作为主要的特征提取网络。该网络通过对 ResNet101 网络的调整改进,使模型检测精度以及性能得到了提高。针对较小牛脸的检测问题,提出改进区域建议网络 RPN(region proposal network)的锚框尺寸调整的方法,通过增加较小尺寸的锚框,使该模型对小目标牛脸的检测能力也得到提高。此外,为了让模型更快地收敛,进行训练时,本文采用了变化的学习率策略,进一步提升了模型的性能和鲁棒性。最后,通过采集制作的牛脸数据集进行实验,改进后的 Mask R-CNN+MResNet 模型不仅在牛脸检测方面表现出良好的效果,而且对于小目标牛脸的漏检和误检问题也得到了改善。

## 1 数据集制作

### 1.1 数据集的建立原则

考虑到最终的牛脸测量模型具有鲁棒化和泛化性能差等特性,将牛脸测试数据集的设置方式大致分为如下几个层面:首先,数据集必须包括牛场的现场所有牛的牛脸图片;其次,图片中牛脸目标必须涵盖多种不同的视角,包括正脸、侧脸等视角的图片;然后,数据集牛脸目标必须包括不同条件下的检测现象,如目标遮挡、光线影响、目标模糊等;最后,为每个图像都标注相应的 XML 文档,用以描述图像的牛脸位置等信息。

数据收集在牛喂料、挤奶和望风的环境下,通过观察、拍摄和处理技术,捕获牛的面部特征共收集了 100 头牛,且每头牛选取了 30 张牛面部图片,合计 3 000 张。

### 1.2 数据清洗

由于部分牛脸图像是使用视频分帧的方式得到的,可能存在一些模糊的牛脸图像或仅包含少部分牛脸的图像,还有一些由于连续帧存在的冗余图像。针对这些问题,本文采取了两种解决方法:首先,对图像质量进行质量筛选和清洗,对于部分模糊或不包含完整牛脸信息的图像选择人为排除,确保数据集的质量和准确性。其次,对于因视频分帧造成的冗余图像,本文采用结构相似度指数 SSIM(structural similarity index measurement)来衡量图像之间的相似度<sup>[7]</sup>,即将每幅图像与随后出现的图像进行比较,找到相似度过高的图片并剔除<sup>[8]</sup>。

### 1.3 数据增强

深度学习模型的性能和泛化能力往往受制于可用的数据样本数量。对于采集难度较大的牛脸图像任务来说,数据样本不足会限制模型的表现。因此,本文对数据集进行扩充将通过旋转、翻转、平移、亮度调节四种方式进行牛脸

图像数据增强,增强效果如图 1 所示。这些数据增强操作可以结合使用,通过随机组合和应用不同的变换,生成更多样化的牛脸图像样本。

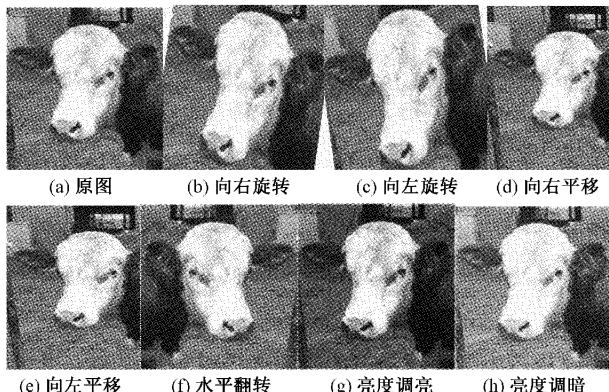


图 1 数据增强

## 2 研究方法

### 2.1 Mask R-CNN 检测模型

2017 年 He 等<sup>[9]</sup>提出 Mask R-CNN 模型,为能够在目标检测的同时进行图像的实例切割,从而实现在计算机视觉任务中更加准确的目标检测位置要求,在 Faster R-CNN 部分引入了一个新的实例分割分支,在完成目标检测的同时提供了一个简单、灵活、通用的实例分割模型框架<sup>[10]</sup>。通过 ROIAlign(region of interest alignment)方法得到了比较精确的图像信息,并使用全卷积网络方法得到了比较有效的二值掩码<sup>[11]</sup>,并由此促进牛脸的目标分析与实例分割方法的结合应用。针对目标检测的数据集中展开了研究,检测结果显示,该技术均取得了很好的成效。

Mask R-CNN 算法主要由两大分支组成,即检测分支和分割分支。检测分支实现了对图像中目标的定位及分类,分割分支则通过全卷积网络 FCN(fully convolutional network)生成二值掩码实现实例分割,达到像素级的区分效果<sup>[11-12]</sup>。

在 Mask R-CNN 模型中,分割分支是实现精确分割的关键部分之一。通过二值掩码,可以将牛脸区域与背景区域进行精确的分割,使得每个像素都能被准确地分类为牛脸或背景。通过有效的牛脸与背景分离,Mask R-CNN 模型在实例分割任务中具有出色的性能,能够在复杂的图像场景中准确地分割出牛脸目标,并为后续的应用提供高质量的分割结果。Mask R-CNN 模型框架如图 2 所示。

Mask R-CNN 检测步骤:主要是通过 ResNet101 与特征金字塔 FPN(feature pyramid networks)结合作为特征提取网络,且为了加快生成特征图中的候选区域,使用区域推荐网络(region proposal network, RPN),通过对特征图进行滑动窗口操作,生成一系列候选区域,从而捕捉到可能包含目标的区域。此网络将首先选择大小为  $3 \times 3$  卷积核作

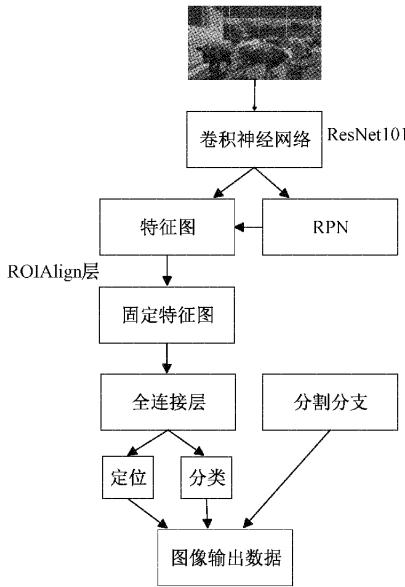


图 2 Mask R-CNN 算法模型框架

为可以滑动的窗口进行特征图的遍历(采用从上到下、从左至右的通常方式)工作;滑动窗口每滑动到一个位置,与滑动窗口中心相对应的输入图片的区域中心将产生 9 个锚框,由 3 种尺度(128、256、512)和 3 种长宽比(1 : 1、1 : 2、2 : 1)构成了这 9 个锚框<sup>[13]</sup>。然后,进行候选区域匹配(RoIAlign)操作,可以获得尺寸大小一致的特征图,以便后续的目标检测和分割操作。使用分类分支对目标进行定位和分类;并使用带有分割分支的全卷积网络在牛脸图像上绘制相应的二进制掩码,完成实例分割,最后对系统分析的结果实现输出。

## 2.2 ResNet101 网络

为了解决网络深度达到饱和后出现的梯度消散或梯度爆炸的问题,2015 年 He 等<sup>[14-15]</sup>提出了残差网络 ResNet。ResNet101<sup>[16-17]</sup>是基于 VGG 网络结构的扩展版本,引入了残差学习模块,形成了一个深度为 101 层的网络结构。3 个卷积层依次串联,并与输入进行合并构成了残差块。这 3 个卷积层的大小分别为  $1 \times 1$ 、 $3 \times 3$  和  $1 \times 1$ 。在每个残差块后面都添加了规范化线性单元(rectified linear unit,ReLU)激活函数。图 3 展示了 ResNet 的残差学习模块的结构。

该模块的输入通过两个分支进行处理,一个分支是直接将输入传递给输出,另一个分支是经过卷积层的处理后与输入相加。这种设计使得网络可以学习到输入的增量变化,从而更好地适应复杂的特征表示。

## 2.3 迁移学习

对于卷积模型而言,迁移学习的核心是利用预训练好的卷积基的特征参数<sup>[18]</sup>。在新模型中,可以将预训练模型的卷积基部分冻结,即不进行参数更新,以保持其学习到的特征表示不变。

冻结卷积基的目的在于保持其在新任务中的特征提取

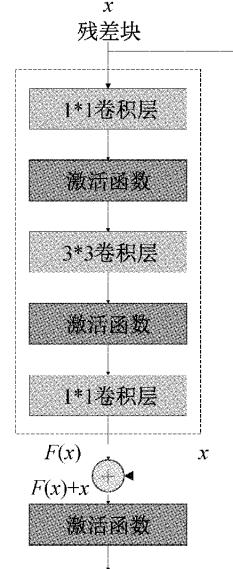


图 3 ResNet101 的残差结构

能力,防止其权重在新数据集上过度调整,从而保留预训练模型在大规模数据集上学到的有用特征。这样可以避免新任务数据量较小时出现过拟合的问题,并提高模型的泛化能力。

在新模型中,需要添加一个新的分类器层,用于针对特定图像分类任务进行训练。这个分类器层通常是一个全连接层或者其他适合任务的分类器结构。这部分是需要进行训练的,通过新任务数据集的标注样本进行参数更新,以适应新任务的特定要求。

## 2.4 改进的 Mask RCNN+ResNet101 模型

### 1) MResNet 网络

基于 ResNet101 网络改进后 MResNet 的网络,改进的主要内容如下:

(1) 进行迁移学习模型调整,这包括删除了最后的平均池化层和分类层,冻结 Conv1 ~ Conv4\_x 层(冻结前 312 层),并对 Conv5\_x 层进行参数重训练。

(2) 通过 Dropout 正则化处理(Dropout regularization),将舍弃概率值调整为 0.5<sup>[19]</sup>。Dropout 正则化旨在减少神经网络中的过拟合问题。在训练网络时舍弃 1/2 的参数,即将部分神经元的输出调整为 0,使得参数对输出结果的依赖性减少。

(3) 将 softmax 层(softmax function)的输出神经元个数设置为 62。

### 2) 改进的 Mask R-CNN 模型

牛脸图像输入 Mask R-CNN 模型后,MResNet 网络与 FPN 网络的融合将提取特征图<sup>[20]</sup>。并将提取的特征图输入到 RPN 中。为了搜索包含物体的候选区域,它利用了滑动窗口法在卷积特征图上进行搜索。具体来说,RPN 通过在深层的卷积特征图上滑动一个小网络。

目前锚框大小是无法有效检测较小的牛脸,可能会出现漏检或者误检的情况;RPN 网络的目标是区分出图片中牛脸和背景,如果锚框的尺寸较大了,那么较小的牛脸在锚框中所占的比例较小,容易被误认为是背景去掉。从而导致 Mask R-CNN 模型无法检测,因此需要针对较小的牛脸调整锚框的大小,以确保模型能够捕捉到这些小牛脸的目标。基于上述分析,本文将加入 32、64 两种小尺寸的锚框方案。每个位置都使用了 32、64、128、256、512 五种尺度和 1 : 1、1 : 2、2 : 1 长宽比,共形成了 15 个锚框,调整后 Mask R-CNN 模型具有了对较小目标的能力,使得模型能够更准确地捕捉到图像中较小的牛脸。

RPN 的子网络结构如图 4 所示,针对 RPN 网络产生的  $k$  个不同的锚框,采取两个分支,其中一个分支输出了  $2 \times k$  个目标和背景的概率数值,另一个分支输出了  $4 \times k$  个位置坐标,未改进的是 9 个锚框,则  $k=9$ ;改进后的网络有 15 个锚框, $k=15$ 。

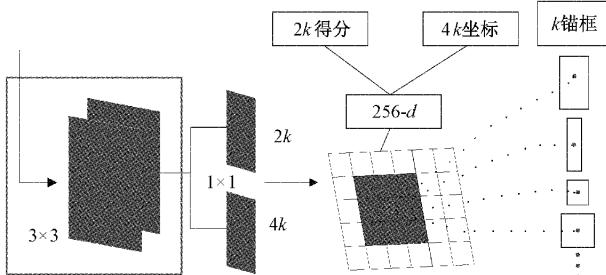


图 4 RPN 的子网络结构

RPN 结构如图 5 所示,结构的输出被分成两个分支。第一个分支将  $2 \times k$  个目标和背景的概率数值,并传递到 RPN 网络的下一阶段,这个阶段能够完成锚框是背景还是前景的判别任务,这项工作需要 softmax 分类完成;另一个分支输入的  $4 \times k$  个位置坐标将用于计算锚框的边框回归(bounding box regression)偏移量,以获得精确的候选框(proposal)。

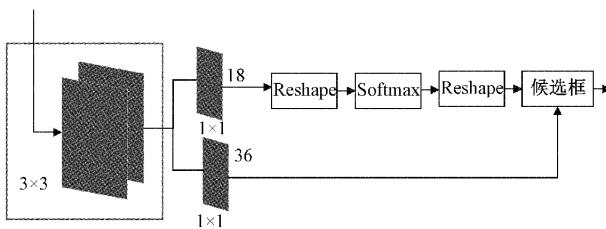


图 5 RPN 结构

最后的 proposal 层在目标检测中起着关键作用。在 proposal 层中,通过综合前景锚框和偏移量,根据一定的阈值和筛选规则,选择最具有潜在目标的候选框。通常会剔除太小和超出边界候选框,以确保最终选择的候选框具有较好的质量和适应性,为后续的实例分割和目标检测提供良好的基础。

### 3 实验与结果分析

#### 3.1 实验设置

本文选择了初始学习率为 0.000 2 的变化学习率策略作为模型的学习率。即在迭代 1~2 000 次时,将学习率设置为 0.000 2;在迭代 2 000~4 000 次时,将学习率设置为 0.000 1;在迭代 4 000~6 000 次时,将学习率设置为 0.000 01;

在实验中,数据集按照 4 : 1 分为训练集和测试集。为了让训练模型可以快速地收敛以及提高检测效率,需要将每种检测方法的预练习模型作为网络的初始权重。实验环境具体配置情况如表 1 所示。

表 1 实验环境具体配置情况

类别	具体配置
操作系统	Windows11
系统类型	64 位操作系统
GPU	NVIDIA RTX 30
显卡	GTX3070Ti
内存	16 G
运算平台	Cuda 10.1
编程语言	Python3. 7
编译器	Pycharm
深度学习框架	Tensorflow2. 2. 0 + Keras2. 3. 1

#### 3.2 实验对比分析

为了验证 MResNet 网络在牛脸图像检测问题上的有效性,进行了一系列实验。首先,基于迁移学习的方法,分别对 ResNet101 模型、调整第 5 组卷积块后的模型、添加 Dropout 正则化和批量正则化技术后的模型进行训练。在训练过程中,选用了 Adam 优化器和交叉熵损失函数。每个模型都进行了 6 000 次迭代,并根据测试准确率的最大值来评估模型的性能。模型性能比较如表 2 所示。

表 2 调整模型训练结果比较

模型	测试精度/%	测试损失
ResNet101	78.7	1.5
ResNet101+调整 Conv5_x	83.4	1.5
ResNet101+调整正则化	87.9	1.4
MResNet	<b>91.3</b>	<b>0.7</b>

从表 2 可知,相对于原始模型,卷积块被调整后的模型准确率提高了 4.7%、正则化技术的引入,使得模型的准确率提高了 4.5%,并且模型损失值均低于原始模型,证明该方法使得过模型拟合的问题在一定程度上缓解,并且在牛脸检测问题上显示出可行性。通过调整卷积块和引入正则化技术,模型的性能得到了显著提升。测试准确率的提高以及损失的降低表明,改进后的模型在学习牛脸图像特

征和分类任务上表现更好。最终改进模型 MResNet 的测试准确率达 91.3%，与原始模型相比，准确率提升了 12.6%，测试损失降低了 0.8。图 6、7 分别显示了 ResNet101 与 MResNet 网络训练过程的损失值和准确率的变化曲线。

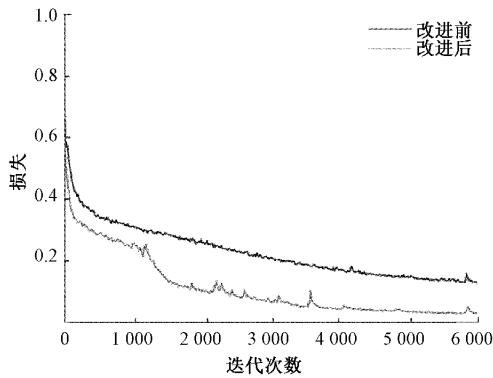


图 6 ResNet101 与 MResNet 网络的训练损失函数变化曲线

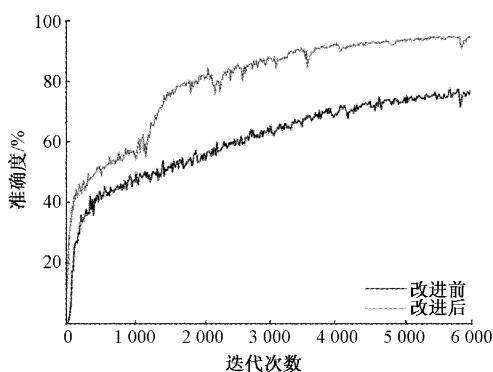


图 7 ResNet101 与 MResNet 网络的训练准确率变化曲线

通过图 7 可以观察到 MResNet 网络在识别精度方面表现较好。原始的 ResNet101 网络随着迭代次数的增加，其识别精度稳步提高，并最终接近 78.7% 的准确率。而 MResNet 网络模型测试精度能达到 91.3%。

通过实验分析,如图 8 所示得出的结论:随着训练步数的提高,模型的  $M_{MAP}$  数值也将逐步提高,其中改进后 Mask-MResNet 模型的  $M_{MAP}$  数值最大,最高为 97.33%;改进后 Mask R-CNN 模型使用 ResNet101 网络作为特征提取的网络效果要低于使用 MResNet 网络,  $M_{MAP}$  数值达到 96.12%;而改进后 Mask R-CNN 使用 ResNet50 作为特征提取网络效果较差,  $M_{MAP}$  值最高达到 93.21%。

表 3 展示了在不同环境下 3 种检测方法的  $M_{MAP}$  值。在不同视角,不同光线条件下,3 种方法对牛脸的检测精度都较高,表明了 3 种检测模型能适应不同视角与光线的变化。但在小目标检测下,除改进后 Mask-MResNet 模型有良好的检测效果外,其他两种模型算法检测效果都不理想。

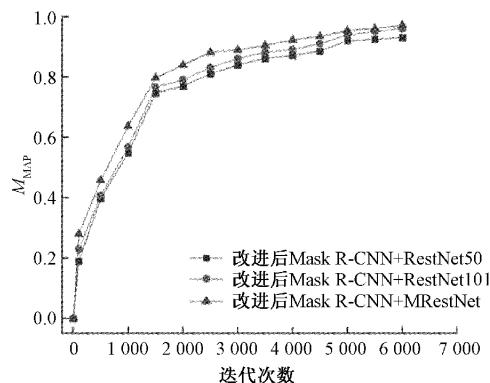


图 8 3 种算法的  $M_{MAP}$  曲线

表 3 不同环境下  $M_{MAP}$  值

检测	改进后	改进后	改进后
	Mask R-CNN+ResNet50	Mask R-CNN+ResNet101	Mask R-CNN+MResNet
视角	95.3	97.5	97.9
多目标	90.1	90.5	92.3
小目标	83.2	85.7	88.1
遮挡	81.3	83.3	85.5
光线	93.4	96.4	97.1
模糊	89.8	93.3	93.9

由图 9 可知,基于 Mask R-CNN+MResNet 模型的检测准确度最高达到了 0.990;但是可以清晰的看到,对于小目标的牛脸都出现了漏检的情况。

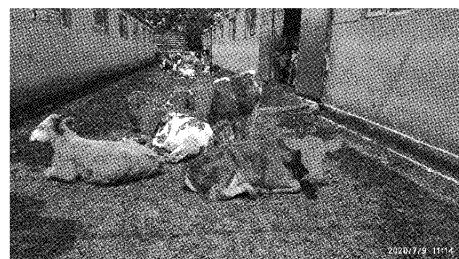


图 9 Mask R-CNN+MResNet 检测结果分析

通过对 Mask R-CNN 模型改进,检测精度得到了提高,捕获小目标牛脸的能力也得到了提高。图 10~12 是分别基于新型 Mask R-CNN+ResNet50 模型、基于新型 Mask R-CNN+ResNet101 模型、基于新型的 Mask-MResNet 模型的牛脸检测效果图。

通过对图分析可以看出,在图 9 中出现漏检的情况,通过对模型的改进图 12 中提高了检测精度的同时也检测到了部分漏检的小目标牛脸。

通过对比分析图 10~12,改进后 Mask R-CNN 选取 MResNet 网络作为主干特征提取网络检测结果要明显优于选取 ResNet50、ResNet101 网络的检测结果。



图 10 新型 Mask R-CNN+ResNet50 检测结果分析

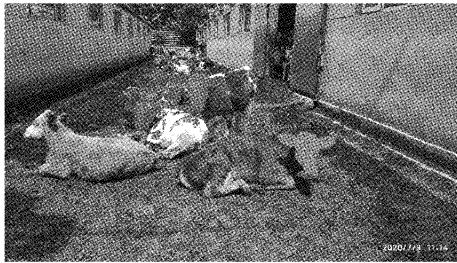


图 11 新型 Mask R-CNN+ResNet101 检测结果分析

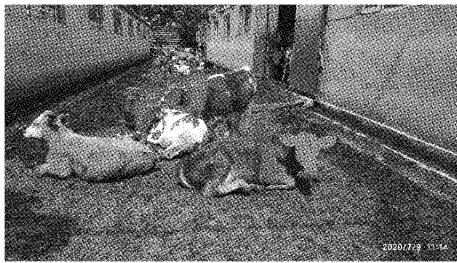


图 12 改进后 Mask R-CNN+MResNet 检测结果分析

## 4 结 论

针对牛脸检测时存在检测精度不高、牛脸较小被漏检或误检等问题,本文所提出的 MResNet 网络在牛脸检测的任务上取得了良好的性能。测试精度达到了 91.3%,相比原始的网络模型,检测精度提高了 12.6%。并对 Mask R-CNN 模型中的 RPN 网络的描框尺寸进行了改进。进行模型训练时将学习率调整为变化的学习率。根据实验结果,说明通过改进的方法,能够成功地检测出图片中较小的牛脸目标,并具有更高的检测准确性。此外,改进后 Mask R-CNN+MResNet 模型在各种复杂环境下都展现出良好的牛脸目标检测能力。意味着该模型能够适应不同的光照条件、角度变化以及其他干扰因素,具有较强的鲁棒性和通用性。证明了提出的改进方案在牛脸目标实际应用中的有效性。

## 参考文献

- [1] 宋肖肖. 牛脸特征点检测的研究与实现[D]. 杨凌: 西北农林科技大学, 2017.
- [2] 汪文华. 基于身体特征图像及深度学习的奶牛身份识别方法的研究[D]. 呼和浩特: 内蒙古大学, 2019.
- [3] 刘爽. 基于深度学习的西门塔尔肉牛面部识别的研究[D]. 呼和浩特: 内蒙古大学, 2020.
- [4] 张晨鹏. 基于深度学习的牛脸检测与个体身份识别方法研究[D]. 呼和浩特: 内蒙古工业大学, 2021.
- [5] 姜世奇. 基于计算机视觉的牛个体身份识别方法研究[D]. 包头: 内蒙古科技大学, 2023.
- [6] 杨梅, 赵建敏. 基于三元损失的保险业务牛脸识别系统的设计[J]. 光电子、激光, 2022, 33(8): 9.
- [7] 秦兴, 宋各方. 基于双线性卷积神经网络的猪脸识别算法[J]. 杭州电子科技大学学报(自然科学版), 2019, 39(2): 12-17.
- [8] 申凯旋. 基于移动终端的牛脸快速识别算法研究[D]. 呼和浩特: 内蒙古工业大学, 2021.
- [9] HE K, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN [C] Proceedings of the IEEE International Conference on Automatic Face and Gesture Recognition. Piscataway, NJ: Institute of Electrical and Electronics Engineers Inc., United States: 2017: 2961-2969.
- [10] 洪吉晨. 基于深度学习的鲁棒声呐目标实时检测方法研究[D]. 杭州: 杭州电子科技大学, 2023.
- [11] 林凯瀚, 赵慧民, 吕巨建, 等. 基于 Mask R-CNN 的人脸检测与分割方法[J]. 计算机工程, 2020, 46(6): 7.
- [12] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2015: 3431-3440.
- [13] 曹凯宁. 基于深度学习的车辆目标检测[D]. 长春: 吉林大学, 2023.
- [14] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[J]. IEEE, 2016, DOI: 10.1109/CVPR.2016.90.
- [15] 黄健, 张钢. 深度卷积神经网络的目标检测算法综述[J]. 计算机工程与应用, 2020, 56(17): 12.
- [16] 李学威, 薛占熬. 基于 ResNet 及损失函数的模糊图像复原算法[J]. 国外电子测量技术, 2023, 42(5): 27-34.
- [17] 齐爱玲, 王宣淋. 融合通道与位置信息的 ResNet 细粒度图像识别[J]. 国外电子测量技术, 2022, 41(12): 103-111.
- [18] 翟永杰, 胡哲东, 白云山, 等. 融合迁移学习的绝缘子缺陷分级检测方法[J]. 电子测量技术, 2023, 46(6): 23-30.
- [19] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: A simple way to prevent neural networks from overfitting [J]. Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [20] 吴华运, 任德均, 吕义钊, 等. 基于改进的 RetinaNet 医药空瓶表面气泡检测[J]. 四川大学学报: 自然科学版, 2020, 57(6): 6.

## 作者简介

关忠榜, 硕士研究生, 主要研究方向为牛脸的目标检测。  
E-mail: gzb\_6593@126.com

杨颜博(通信作者), 博士, 讲师, 主要研究方向为大数据、人工智能算法的理论与应用研究、网络编码理论与应用研究。  
E-mail: yangyanbo@imust.edu.cn

李敏超, 博士, 讲师, 主要研究方向为阵列信号处理; 雷达探测与成像和人工智能方向。