

基于深度学习的群体种鸭蛋受精信息检测方法

李庆旭¹ 王巧华^{1,2} 肖仕杰¹ 顾伟¹ 马美湖³

(1. 华中农业大学工学院, 武汉 430070; 2. 农业农村部长江中下游农业装备重点实验室, 武汉 430070;
3. 国家蛋品研发中心, 武汉 430070)

摘要: 针对我国禽蛋孵化行业以人工方式剔除无精蛋自动化程度低的问题,以孵化5 d 的群体种鸭蛋为研究对象,利用图像采集装置采集群体种鸭蛋图像,在常用单步多框检测器 (Single shot multibox detector, SSD) 网络的基础上提出一种改进 SSD 目标检测算法,并采用该方法对孵化早期整盘群体种鸭蛋中的受精蛋与无精蛋进行识别。利用 MobileNetV3 轻量化网络作为模型的特征提取网络,可快速高效提取图像特征。结果表明:本文建立的模型对孵化早期群体种鸭蛋中受精蛋与无精蛋的平均识别精度为 98.09%、召回率为 97.32%、漏检率为 0,优于改进前网络模型的 96.88%、96.17%、1.04%。本文方法可为种鸭蛋孵化产业相关智能机器人或机械手的研发提供技术支持。

关键词: 群体受精鸭蛋; MobileNetV3; 单步多框检测器; 深度学习

中图分类号: TP391.4; S834+.83 文献标识码: A 文章编号: 1000-1298(2021)01-0193-08 OSID: 

Detection Method for Fertilizing Information of Group Duck Eggs
Based on Deep Learning

LI Qingxu¹ WANG Qiaohua^{1,2} XIAO Shijie¹ GU Wei¹ MA Meihu³

(1. College of Engineering, Huazhong Agricultural University, Wuhan 430070, China
2. Key Laboratory of Agricultural Equipment in Mid-Lower Yangtze River, Ministry of Agriculture and Rural Affairs, Wuhan 430070, China
3. National Egg Research and Development Center, Wuhan 430070, China)

Abstract: The method of removing unfertilized eggs in China’s poultry egg incubation industry relies on artificial irradiation of eggs, with low degree of automation. The accurate identification of fertilized eggs in group duck eggs during the early incubation period is the key technology to realize the automation and intelligence of the incubation process. A group of duck eggs hatched for five days was taken as the research object, and the images of the group duck eggs were collected using corresponding image acquisition devices. Based on the commonly used single shot multibox detector (SSD) network, an improved SSD target detection algorithm was proposed to accurately identify the fertilized eggs and non-fertilized eggs in the eggs of early hatching period. Using MobileNetV3 lightweight network as a model feature extraction network to quickly and efficiently extract image features. At the same time, the inverse residual block was used instead of the standard convolution layer in the SSD regression detection network to improve the detection network efficiency. The results showed that the average recognition accuracy of the model was 98.09%, the recall rate was 97.32%, and the missed detection rate was zero. It was better than 96.88%, 96.17% and 1.04% of the network model before the improvement. Therefore, this method can provide a new basis for the research and development of intelligent robot or robot hand related to duck egg incubation industry and accelerate the intellectualization of poultry egg incubation industry.

Key words: group fertilized duck eggs; MobileNetV3; single shot multibox detector; deep learning

收稿日期: 2020-04-06 修回日期: 2020-04-29
基金项目: 国家自然科学基金面上项目(31871863)
作者简介: 李庆旭(1994—),男,博士生,主要从事图像处理 and 深度学习研究, E-mail: 1948260008@qq.com
通信作者: 王巧华(1970—),女,教授,博士生导师,主要从事农产品智能化检测技术与装备研究, E-mail: wqh@mail.hzau.edu.cn

0 引言

目前,我国禽蛋孵化产业自动化程度较低,主要采用人工照蛋方式剔除无精蛋。人工照蛋方式准确率低、速度慢,且影响到孵化饲养健康,亟需相关自动化装置代替人工,对无精蛋进行快速、精确检测及剔除^[1]。针对此问题,研究者提出了机器视觉^[2-3]、光谱^[4-5]、敲击振动^[6]等方法,对禽蛋的受精信息进行无损检测,均取得了较好的检测效果。但这些方法均针对单枚种蛋,检测效率较低,很难应用于实际生产中。因此,对整盘群体禽蛋中受精蛋的精准识别是解决该问题的关键。文献[7]利用称量法结合机器视觉对群体种鸡蛋中的受精蛋进行检测,对孵化 7 d 的种鸡蛋检测精度为 96.7%,由于需要每天对种蛋进行称量,故实际生产难度依然很大。

整盘群体禽蛋中受精蛋的检测难点在于群蛋的图像分割,特别是在群蛋中无精蛋较多的情况下。近些年,深度学习已成功应用于机器视觉领域,R-CNN^[8]、YOLO^[9]、SSD^[10]等基于深度学习的目标检测算法有效地解决了复杂背景下的图像分割和图像识别问题。基于深度学习的目标检测算法在农业领域已被广泛使用^[11-15]。

将深度学习引入机器视觉中,对群体种鸭蛋中受精蛋进行精准识别,并且检测出受精蛋的位置信息,可为后续相关机器人和机械手的研发提供技术支持。因此,本文以孵化 5 d 的群体种鸭蛋为研究对象,在常用的 SSD-MobileNet^[16] 目标检测算法的基础上,提出一种以 MobileNetV3^[17] 作为 SSD 特征提取网络的群体种鸭蛋受精信息检测方法。

1 材料与方法

1.1 数据采集

为采集大量图像数据,选取湖北省神丹种鸭养殖基地的缙云麻鸭种蛋 7 776 枚作为试验材料,进行 3 次试验,每次试验条件与试验方法完全相同。将种鸭蛋用酒精擦拭消毒并编号后放入智能孵化箱内孵化。为了模型后续部署实际生产时具有较好的泛化能力,模拟实际生产环境搭建了一套由 CCD 相机、整盘照蛋器、计算机、暗箱、LED 光源、蛋盘等构成的图像采集装置,如图 1 所示。每隔 24 h 采集一次图像,种鸭蛋竖直放置于蛋盘,对应种鸭蛋的编号在图像中的位置均有记录。共采集获得 324 幅图像,每幅图像含有种鸭蛋 24 枚。在孵化 15 d 后对鸭蛋进行破壳处理,获得精准的受精结果,作为后续评价模型判别性能的真实依据。

采集得到的原始图像如图 2 所示,图像尺寸为




图 1 图像采集装置

Fig.1 Image acquisition system

1. 计算机 2. 镜头 3. CCD 相机 4. 暗箱 5. 蛋盘 6. LED 光源 7. 整盘照蛋器




图 2 原始图像

Fig.2 Original image

1 634 像素 × 1 234 像素。随着孵化时间的增加受精蛋内受精卵会形成血管,同时蛋白粘度也发生变化^[18],孵化 5 d 的群体种鸭蛋在功率为 10 W 的 LED 光源透射下,受精蛋的颜色呈暗红色,无精蛋颜色则较为明亮。差异较为明显,为使用 SSD 目标检测算法实现受精蛋和无精蛋的识别提供了可能性。

1.2 数据集准备

使用 SSD 目标检测算法训练前,需要对采集的原始图像进行人工标注。选择当前常用的 LabelImage 标注工具,对群体种鸭蛋图像中的受精蛋和无精蛋进行人工标注,标注完成后自动生成含有类别和位置信息的 xml 文件。标注完成后将 324 幅图像划分为训练集、测试集和验证集,其中训练集 210 幅图像、测试集 90 幅图像、验证集 24 幅图像。虽然图像数量相对较少,但是每幅图像含有 24 个种鸭蛋样本,324 幅图像中含边框标注样本个数为 7 776(其中受精蛋和无精蛋比例约为 1:1),训练集中受精蛋 2 700 枚,测试集中受精蛋 927 枚,验证集中受精蛋 261 枚,基本能够满足深度学习样本数量要求,故不再对数据进行扩增。最终将数据按照 PASCAL VOC 数据集的格式存储。

2 群体种鸭蛋识别 SSD 网络改进

2.1 SSD-MobileNet 网络结构

SSD-MobileNet 网络是基于经典 SSD 网络改进而来的 one-stage 目标检测算法,目前在工程中被

广泛应用^[19]。将经典的 SSD 网络分为基础网络和辅助网络,基础网络由去除分类层的 VGG 网络实现对输入图像特征的提取;辅助网络是一种基于前向传播的卷积神经网络,用于产生固定尺寸和比例的边框,最后结合非极大值抑制算法实现目标位置的预测。MobileNet 网络^[20]是基于深度可分离卷积的深度神经网络,深度可分离卷积结构如图 3 所示。对于输入为 $m \times n \times n$ (m 为通道数, n 为特征尺寸) 的特征图,卷积核为 $m \times b \times b \times k$ (b 为卷积核尺寸, k 为卷积核个数),则深度可分离卷积的参数量为 $b \times b \times m \times n \times n + m \times k \times n \times n$,而标准卷积的参数量为 $b \times b \times m \times k \times n \times n$ 。深度可分离卷积的参数量为标准卷积的 $\frac{1}{k} + \frac{1}{n \times n}$,此外 MobileNet 网络还引入了宽度因子和分辨率因子 2 个超参数,加速了神经网络的计算速度。




图 3 深度可分离卷积结构

Fig. 3 Depth separable convolution structure

SSD - MobileNet 网络将经典 SSD 的基础网络由 VGG 网络替换为 MobileNet 网络,作为图像的特征提取网络。SSD - MobileNet 网络结构如图 4 所示,




图 4 SSD - MobileNet 网络结构

Fig. 4 SSD - MobileNet network structure

网络的前端为 MobileNet 网络,后端为 SSD 辅助网络。从图 4 可以看出,SSD - MobileNet 的 Conv11、Conv13、Conv14 - 2、Conv15 - 2、Conv16 - 2、Conv17 - 2 特征层的每个单元产生的默认框个数分别为 3、6、6、6、6、6,每个类别生成 1 917 个默认框。默认框中含有位置和类别信息,与人工标注的真实目标的位置和类别信息相比会有一定误差。检测框架需要同时进行位置和类别预测,最后通过非极大值抑制方法得到检测结果。训练的过程是使检测框架预测值与真实值误差不断减小的过程,使用位置损失和置信损失(分类损失)的加权和作为总体目标损失函数

$$L(x, c, l, g) = \frac{1}{N} (L_{\text{conf}}(x, c) + \alpha L_{\text{loc}}(x, l, g)) \quad (1)$$

其中 $L_{\text{conf}}(x, c) = - \sum_{i \in p_{os}} x_{ij}^p \lg \hat{c}_i^p - \sum_{i \in n_{eg}} \lg \hat{c}_i^0$ (2)

$$L_{\text{loc}}(x, l, g) = \sum_{i \in p_{os}} \sum_{m \in b_{ox}} x_{ij}^p S_{L1} [l_i^t (l_i^t - \hat{g}_i^t)] \quad (3)$$

($x_{ij}^p \in (0, 1)$)

$$\hat{c}_i^p = \frac{\exp c_i^p}{\sum_p \exp c_i^p} \quad (4)$$

- 式中 N ——匹配默认框的数量
 l ——预测边框坐标
 g ——真实边框坐标
 c ——Softmax 函数对每个类别的置信度
 x ——真实边框与预测边框匹配标志
 S_{L1} ——预测位置与真实位置的平滑 L1 损失
 α ——权重系数 L_{loc} ——位置损失
 L_{conf} ——分类损失
 x_{ij}^p ——第 i 个预测框与类别 p 的第 j 个真实框匹配标志
 p_{os} ——正样本集合

- n_{eg} ——负样本集合
- b_{ox} ——预测框中心坐标及其高和宽的集合
- c_i^p ——第 i 个预测框中目标为类别 p 的置信度
- $\hat{c}_i^p$ ——第 i 个预测框中目标为类别 p 的概率
- $\hat{c}_i^0$ ——第 i 个预测框中没有目标的概率
- l_i^t ——第 i 个预测框 (t 表示预测框的中心坐标及其高和宽)
- $\hat{g}_i^t$ ——第 i 个真实框的位置信息

2.2 基于 MobileNetV3_large 的改进 SSD 网络

MobileNet 网络中用深度可分离卷积代替了标准卷积 (Convolution, Conv2d), 同时引入了宽度因子和分辨率因子, 极大地减少了参数量和计算量。但宽度因子和分辨率因子的引入会丢失大量特征, 且 MobileNet 网络前向传播过程中存在 ReLU 非线性变换, ReLU 激活函数在提取高维空间的特征时能有效增加非线性, 但是在提取低维空间时会破坏特征的非线性, 导致 MobileNet 网络在训练过程中存在线性瓶颈^[21]。为此文献[22]结合深度可分离卷积在逆残差结构的基础上提出了 MobileNetV2 网络, 增强了梯度的传播, 保留了更多的特征。逆残差结构 (Inverse residual structure, IRS) 如图 5 所示, 通过先升维再卷积后降维的操作有效地丰富了特征数量, 同时使用 ReLU6 代替 ReLU 函数作为激活函数, 提升了网络的鲁棒性^[23]。ReLU6 函数的实现公式为

$$Y = \min(\max(X, 0), 6)$$
 (5)

式中 Y ——函数输出 X ——输入特征




图 5 逆残差结构
Fig. 5 Inverse residual structure

为了进一步提升网络的检测速度、减小网络的参数量, 文献[17]在 MobileNetV2 网络基础上提出了 MobileNetV3 网络。MobileNetV3 网络引入了注意力机制模块 (Squeeze-and-Excitation blocks) 改进逆残差结构, 引入注意力机制的逆残差模块 (SE inverse residual convolution structure, SE IRS) 如图 6 所示; 同时使用 H-Swish 函数作为激活函数

$$y = x \frac{\text{ReLU6}(x + 3)}{6}$$
 (6)

式中 y ——H-Swish 函数输出 x ——输入
最后利用资源受限的 NAS (platform-aware NAS) 与 NetAdapt 网络搜索技术确定网络结构, 使得模型的检测精度和检测速度都有了提升。




图 6 改进逆残差模块 (SE 逆残差卷积)
Fig. 6 Improved inverse residual module
(SE inverse residual convolution)

MobileNetV3 网络分为 large 和 small 2 个版本, 两者仅在通道数和网络层数上有所不同。MobileNetV3_large 网络参数如表 1 所示, 共 19 层网络, 包括标准卷积、逆残差卷积、注意力机制逆残差

表 1 MobileNetV3_large 网络参数
Tab. 1 MobileNetV3_large network parameters

输入	操作	激活函数	通道数	步长
224 × 224 × 3	Conv2d	H-Swish	16	2
112 × 112 × 16	IRS, 3 × 3	ReLU	16	1
112 × 112 × 16	IRS, 3 × 3	ReLU	24	2
56 × 56 × 24	IRS, 3 × 3	ReLU	24	1
56 × 56 × 24	SE IRS, 5 × 5	ReLU	40	2
28 × 28 × 40	SE IRS, 5 × 5	ReLU	40	1
28 × 28 × 40	SE IRS, 5 × 5	ReLU	40	1
28 × 28 × 40	IRS, 3 × 3	H-Swish	80	2
14 × 14 × 80	IRS, 3 × 3	H-Swish	80	1
14 × 14 × 80	IRS, 3 × 3	H-Swish	80	1
14 × 14 × 80	IRS, 3 × 3	H-Swish	80	1
14 × 14 × 80	SE IRS, 3 × 3	H-Swish	112	1
14 × 14 × 112	SE IRS, 3 × 3	H-Swish	112	1
14 × 14 × 112	SE IRS, 5 × 5	H-Swish	112	1
14 × 14 × 112	SE IRS, 5 × 5	H-Swish	160	2
7 × 7 × 160	SE IRS, 5 × 5	H-Swish	160	1
7 × 7 × 160	Conv2d, 1 × 1	H-Swish	960	1
7 × 7 × 960	Pool, 7 × 7	H-Swish		
1 × 1 × 960	Conv2d, 1 × 1	H-Swish	1 280	1
1 × 1 × 1 280	Conv2d, 1 × 1		k	

卷积及池化(Pool)等操作。针对群体种鸭蛋中受精蛋与无精蛋差异较为明显,为了进一步减少模型的参数量从而提高模型的检测速度,本文对常用的 SSD-MobileNet 网络改进如下:①将去掉分类层和输出层的 MobileNetV3_large 网络代替 MobileNet 作为 SSD 的基础网络。②利用逆残差结构代替 SSD 辅助网络中的标准卷积。③将网络的输入由 $300 \times 300 \times 3$ 改为 $320 \times 320 \times 3$,增加网络的预测精度。改进后的 SSD 网络结构如图 7 所示,每类生成 2 034 个默认框,然后经过检测框架进行预测,最后通过非极大值抑制算法得到种鸭蛋的位置和类别。改进后的 SSD 网络参数如表 2 所示。




Fig. 7 Improved SSD network based on MobileNetV3_large

表 2 基于 MobileNetV3_large 的改进 SSD 网络参数

Tab. 2 SSD network parameters after improvement based on MobileNetV3_large

输入	操作	激活函数	通道数	步长
320 × 320 × 3	Conv2d	H-Swish	16	2
160 × 160 × 16	IRS, 3 × 3	ReLU	16	1
160 × 160 × 16	IRS, 3 × 3	ReLU	24	2
80 × 80 × 24	IRS, 3 × 3	ReLU	24	1
80 × 80 × 24	SE IRS, 5 × 5	ReLU	40	2
40 × 40 × 40	SE IRS, 5 × 5	ReLU	40	1
40 × 40 × 40	SE IRS, 5 × 5	ReLU	40	1
40 × 40 × 40	IRS, 3 × 3	H-Swish	80	2
20 × 20 × 80	IRS, 3 × 3	H-Swish	80	1
20 × 20 × 80	IRS, 3 × 3	H-Swish	80	1
20 × 20 × 80	IRS, 3 × 3	H-Swish	80	1
20 × 20 × 80	SE IRS, 3 × 3	H-Swish	112	1
20 × 20 × 112	SE IRS, 3 × 3	H-Swish	112	1
20 × 20 × 112	SE IRS, 5 × 5	H-Swish	112	1
20 × 20 × 112	SE IRS, 5 × 5	H-Swish	160	2
10 × 10 × 160	SE IRS, 5 × 5	H-Swish	160	1
10 × 10 × 160	Conv2d, 1 × 1	H-Swish	960	1
10 × 10 × 960	IRS, 3 × 3	ReLU6	1024	1
10 × 10 × 1024	IRS, 3 × 3	ReLU6	512	2
5 × 5 × 512	IRS, 3 × 3	ReLU6	256	2
3 × 3 × 256	IRS, 3 × 3	ReLU6	256	2
2 × 2 × 256	IRS, 3 × 3	ReLU6	128	2
1 × 1 × 128		ReLU6		

2.3 基于 MobileNetV3_small 的改进 SSD 网络

MobileNetV3 网络的 small 版本为更加轻量化的网络。为了进一步提升模型的检测速度,利用 MobileNetV3_small 版本代替改进 SSD 群体种蛋检测网络中的基础网络。MobileNetV3_small 网络与 large 版本相比,只是对网络层数和通道数进行了调整,减少了网络的参数量和计算量,其网络参数如表 3 所示,共 15 层网络。

表 3 MobileNetV3_small 网络参数

Tab. 3 MobileNetV3_small network parameters

输入	操作	激活函数	通道数	步长
224 × 224 × 3	Conv2d	H-Swish	16	2
112 × 112 × 16	SE IRS, 3 × 3	ReLU	16	2
56 × 56 × 16	IRS, 3 × 3	ReLU	24	2
28 × 28 × 24	IRS, 3 × 3	ReLU	24	1
28 × 28 × 24	SE IRS, 5 × 5	H-Swish	40	2
14 × 14 × 40	SE IRS, 5 × 5	H-Swish	40	1
14 × 14 × 40	SE IRS, 5 × 5	H-Swish	40	1
14 × 14 × 40	SE IRS, 5 × 5	H-Swish	48	1
14 × 14 × 48	SE IRS, 5 × 5	H-Swish	48	1
14 × 14 × 48	SE IRS, 5 × 5	H-Swish	96	2
7 × 7 × 96	SE IRS, 5 × 5	H-Swish	96	1
7 × 7 × 96	SE IRS, 5 × 5	H-Swish	96	1
7 × 7 × 96	Conv2d, 1 × 1	H-Swish	576	1
7 × 7 × 576	Pool, 7 × 7			1
1 × 1 × 576	Conv2d, 1 × 1	H-Swish	1 024	1
1 × 1 × 1 024	Conv2d, 1 × 1		k	1

本文利用 MobileNetV3_small 网络代替改进 SSD 群体种蛋检测网络中的 MobileNetV3_large 网络,网络输入尺寸为 $320 \times 320 \times 3$,网络结构如图 8 所示。利用 MobileNetV3_small 网络的前 13 层作为 SSD 的基础网络,其他部分与基于 MobileNetV3_large 网络改进的 SSD 群体种蛋检测网络相同,网络参数如表 4 所示,每类生成 2 034 个默认框,经过检测框架进行预测,最后通过非极大值抑制算法获取种鸭蛋的位置和类别信息。

2.4 迁移学习

在深度学习领域中,迁移学习是一种常用的模型训练手段。避免了随机初始化网络权重和偏置等参数导致的模型收敛速度慢和网络的不稳定^[24]。利用大数据集下已经训练好的预训练模型,通过共享网络前端的权值参数,微调网络后端的参数,从而使新任务下的模型训练能够迅速收敛,即使在小数据集下也只需要少量的训练时间和计算资源开销便可以实现对新任务的适应。本文利用 COCO 数据集下预训练好的模型权重初始化 SSD 网络的权重,通过训练对 SSD 网络参数进行微调,进一步减少了模

型的训练时间与资源。




图 8 基于 MobileNetV3_small 的改进 SSD 网络
Fig. 8 Improved SSD network based on MobileNetV3_small

表 4 基于 MobileNetV3_small 改进的 SSD 网络参数
Tab. 4 SSD network parameters after improvement
based on MobileNetV3_small

输入	操作	激活函数	通道数	步长
320 × 320 × 3	Conv2d	H - Swish	16	2
160 × 160 × 16	SE IRS, 3 × 3	ReLU	16	2
80 × 80 × 16	IRS, 3 × 3	ReLU	24	2
40 × 40 × 24	IRS, 3 × 3	ReLU	24	1
40 × 40 × 24	SE IRS, 5 × 5	H - Swish	40	2
20 × 20 × 40	SE IRS, 5 × 5	H - Swish	40	1
20 × 20 × 40	SE IRS, 5 × 5	H - Swish	40	1
20 × 20 × 40	SE IRS, 5 × 5	H - Swish	48	1
20 × 20 × 48	SE IRS, 5 × 5	H - Swish	48	1
20 × 20 × 48	SE IRS, 5 × 5	H - Swish	96	2
10 × 10 × 96	SE IRS, 5 × 5	H - Swish	96	1
10 × 10 × 96	SE IRS, 5 × 5	H - Swish	96	1
10 × 10 × 96	Conv2d, 1 × 1	H - Swish	576	1
10 × 10 × 576	Conv2d, 1 × 1	H - Swish	1 024	1
10 × 10 × 1 024	IRS, 3 × 3	ReLU6	512	2
5 × 5 × 512	IRS, 3 × 3	ReLU6	256	2
3 × 3 × 256	IRS, 3 × 3	ReLU6	256	2
2 × 2 × 256	IRS, 3 × 3	ReLU6	128	2
1 × 1 × 128		ReLU6		

用的目标损失函数为式(1),与 SSD - MobileNet 相同。基于 MobileNetV3 的 large 和 small 网络改进的 SSD 模型底层权重均使用迁移学习的方法进行初始化,其余权重采用均值为 0、方差为 0.03 的高斯分布进行随机初始化。梯度更新是训练过程中不断调整权重和偏置的方法,从而使模型性能不断优化,本文使用批量随机梯度下降算法寻找梯度下降方向。初始学习率设置为 0.04,学习率衰减方法为指数衰减法,衰减率设置为 0.97。训练的批次图像数量 (Batchsize) 设置为 16,最大训练次数设置为 4×10^4 ,单步训练时间约为 2 s,每训练 10 min 保存一次模型的参数。以基于 MobileNetV3_large 网络改进的 SSD 群体种鸭蛋检测网络的训练过程为例,改进前和 small 版本训练过程与之类似。图 9 为使用了迁移学习 (Transfer learning-loss) 及未使用迁移学习 (Normal loss) 的损失函数变化曲线。从图 9 可以看出,基于 MobileNetV3_large 改进的 SSD 网络在使用迁移学习进行训练 1 000 次后迅速收敛,训练 6 000 次后维持在较低水平小幅度振荡;而未使用迁移学习的基于 MobileNetV3_large 改进的 SSD 网络在训练 4 000 次后才开始迅速收敛,训练 9 000 次后维持在较低水平,说明使用迁移学习可以加快模型的收敛速度。




图 9 迁移学习损失函数曲线
Fig. 9 Loss function curves of transfer learning

3 模型训练及结果分析

3.1 试验平台

采用 AMD 锐龙 Threadripper 2920X 型 CPU; NVIDIA GeForce RTX 2080Ti 型 GPU, 11 GB 显存; 128 GB 内存;操作系统为 Windows 10 的硬件训练平台。深度学习框架使用 Tensorflow - GPU 1.14.0, CUDA 9.2 版本的并行计算框架,深度神经网络加速库选择 CUDNN v7.6 版本。本文的 SSD 目标检测模型的训练与测试均在 Python 3.7 版本下完成。

3.2 模型训练

模型训练的过程是模型不断调整自身参数,使得预测值与真实值不断接近的过程,训练过程中使

3.3 结果分析

3.3.1 评价指标

目前评价基于深度学习的目标检测模型性能的主要手段是测试模型在验证集数据上的检测效果。常用的技术指标有准确率、召回率、漏检率、检测速度和模型占用内存。本文利用训练好的 SSD - MobileNet 模型和改进后 SSD 模型分别对验证集 24 幅图像 (含 576 个种鸭蛋)进行测试,用上述 5 个评价指标对比两者的优劣。漏检率 M 定义为

$$M = \frac{B}{A} \times 100\%$$

(7)

式中 A ——鸭蛋总数量
 B ——误把鸭蛋当作背景的数量

3.3.2 测试结果及分析

对孵化 5 d 后的 24 幅群体种鸭蛋图像的测试结果进行统计,包括准确率、召回率、漏检率、检测速度和模型占用内存 5 项评价指标。共 576 枚种鸭蛋,SSD - MobileNet 错判了 18 枚种鸭蛋(其中将无精蛋判为受精蛋 10 枚,将受精蛋判为无精蛋 2 枚,漏检 6 枚),基于 MobileNetV3_large 改进的 SSD 错判了 11 枚种鸭蛋(其中将无精蛋判为受精蛋 7 枚,将受精蛋判为无精蛋 4 枚,漏检 0 枚),基于 MobileNetV3_small 改进的 SSD 错判了 20 枚种鸭蛋(其中将无精蛋判为受精蛋 9 枚,将受精蛋判为无精蛋 3 枚,漏检 8 枚),统计结果如表 5 所示。

通过表 5 可以发现,基于 MobileNetV3_large 改进的 SSD 模型在精度和速度方面均优于改进前的 SSD - MobileNet 网络,基于 MobileNetV3_small 改进的 SSD 模型检测速度最快,但精度相比改进前的 SSD - MobileNet 网络未有提升。综合考虑检测精度和速度,基于 MobileNetV3_large 改进的 SSD 模型对群体种鸭蛋的识别效果最佳。基于 MobileNetV3_

large 改进的 SSD 模型的检测速度可以达到 68 f/s,远快于改进前的 45 f/s,且模型占用内存仅为 9.10 MB,满足部署到嵌入式系统的模型参数要求。此外漏检率是衡量模型可靠性的重要指标,改进后 SSD 模型的漏检率为 0,说明模型的可靠性远高于 SSD - MobileNet 网络和基于 MobileNetV3_small 改进的 SSD 网络。图 10 为同一幅群体种鸭蛋图像 SSD - MobileNet 模型、基于 MobileNetV3_large 改进的 SSD 模型和基于 MobileNetV3_small 改进的 SSD 模型的检测结果。

表 5 模型测试结果
Tab.5 Model test results

模型	准确率/%	召回率/%	漏检率/%	检测速度/(f·s ⁻¹)	模型占用内存/MB
SSD - MobileNet	96.88	96.17	1.04	45	21.6
基于 MobileNetV3_large 改进的 SSD	98.09	97.32	0	68	9.10
基于 MobileNetV3_small 改进的 SSD	96.53	96.55	1.38	81	4.21




图 10 检测结果

Fig.10 Detection results

4 结论

(1)运用 MobileNetV3_large 网络代替 MobileNet 网络作为 SSD 的基础网络,并使用逆残差结构代替 SSD 辅助网络中的标准卷积,对群体种鸭蛋中受精蛋和无精蛋的识别性能最佳,准确率和召回率分别为 98.09%、97.32%,漏检率为 0。模型占用内存仅为 9.10 MB,检测速度可达到 68 f/s,具有很好的鲁棒性,可满足实际生产要求。

(2)通过迁移学习,将 COCO 大数据集下预训

练好的模型权重迁移到群体种鸭蛋中受精蛋和无精蛋的检测任务下,加速了模型的收敛速度,节约了训练成本。

(3)将群体种蛋中的个体单独分割出来,对每个种蛋进行受精识别,解决了群体种蛋图像难以分割的问题。利用卷积神经网络端对端的特点,输入一幅群体种鸭蛋图像可直接检测出种蛋的类别和位置信息,为群体种蛋受精信息检测提供了一种思路,加速了禽蛋孵化行业的智能化,也为后续研发相关自动化设备提供了技术支持。

参 考 文 献

[1] 李庆旭,王巧华,顾伟,等. 基于深度学习的种鸭蛋孵化早期受精信息无损检测[J/OL]. 农业机械学报,2020,51(1): 188 - 194.
LI Qingxu,WANG Qiaohua, GU Wei,et al.Non-destructive testing of early fertilization information in duck egg laying based on deep learning[J/OL]. Transactions of the Chinese Society for Agricultural Machinery,2020,51(1):188 - 194. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20200120&flag=1. DOI:10.6041/j.issn.1000-1298.2020.01.020. (in Chinese)
[2] 马秀莲,衣淑娟. 基于嵌入式系统与机器视觉的上孵前无精蛋识别系统[J]. 农业机械学报,2011,42(5):187 - 192.

- MA Xiulian, YI Shujuan. Unfertilized eggs verification system before hatching based on embedded system and machine vision [J]. Transactions of the Chinese Society for Agricultural Machinery, 2011, 42(5): 187–192. (in Chinese)
- [3] HASHEMZADEH M, FARAJZADEH N. A machine vision system for detecting fertile eggs in the incubation industry [J]. International Journal of Computational Intelligence Systems, 2016, 9(5): 850–862.
- [4] 秦五昌, 汤修映, 彭彦昆, 等. 基于可见/近红外透射光谱的孵化早期受精鸡蛋的判别[J]. 光谱学与光谱分析, 2017, 37(1): 200–204.
- QIN Wuchang, TANG Xiuying, PENG Yankun, et al. Identification of fertilized chicken eggs based on visible/near-infrared spectrum during early stage [J]. Spectroscopy and Spectral Analysis, 2017, 37(1): 200–204. (in Chinese)
- [5] DONG Jun, DONG Xiaoguang, LI Yanlei, et al. Identification of unfertilized duck eggs before hatching using visible/near infrared transmittance spectroscopy [J]. Computers and Electronics in Agriculture, 2019, 157: 471–478.
- [6] 张伟, 屠康, 刘鹏, 等. 基于机器视觉与敲击振动融合的鸭蛋孵化特性检测[J/OL]. 农业机械学报, 2012, 43(2): 140–145.
- ZHANG Wei, TU Kang, LIU Peng, et al. Early fertility detection of hatching duck egg based on fusion between computer vision and impact excitation [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2012, 43(2): 140–145. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20120228&flag=1. DOI: 10.6041/j.issn.1000-1298.2012.02.028. (in Chinese)
- [7] 吴林峰, 余怀鑫, 祝志慧. 基于机器视觉的孵化早期群体受精蛋鉴别[J]. 食品与机械, 2019, 35(4): 152–156.
- WU Linfeng, YU Huaixin, ZHU Zhihui. Identification group of fertilized eggs infertile and eggs in early hatching stage based on machine vision [J]. Food & Machinery, 2019, 35(4): 152–156. (in Chinese)
- [8] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [C] // Advances in Neural Information Processing Systems, 2015: 91–99.
- [9] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection [C] // IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 779–788.
- [10] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector [C] // European Conference on Computer Vision, 2016: 21–37.
- [11] 彭红星, 黄博, 邵园园, 等. 自然环境下多类水果采摘目标识别的通用改进 SSD 模型[J]. 农业工程学报, 2018, 34(16): 155–162.
- PENG Hongxing, HUANG Bo, SHAO Yuanyuan, et al. General improved SSD model for picking object recognition of multiple fruits in natural environment [J]. Transactions of the CSAE, 2018, 34(16): 155–162. (in Chinese)
- [12] 刘慧, 张礼帅, 沈跃, 等. 基于改进 SSD 的果园行人实时检测方法[J/OL]. 农业机械学报, 2019, 50(4): 29–35, 101.
- LIU Hui, ZHANG Lishuai, SHEN Yue, et al. Real-time pedestrian detection in orchard based on improved SSD [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(4): 29–35, 101. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20190403&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2019.04.003. (in Chinese)
- [13] 吕石磊, 卢思华, 李震, 等. 基于改进 YOLOv3-LITE 轻量级神经网络的柑橘识别方法[J]. 农业工程学报, 2019, 35(17): 205–214.
- LÜ Shilei, LU Sihua, LI Zhen, et al. Orange recognition method using improved YOLOv3-LITE lightweight neural network [J]. Transactions of the CSAE, 2019, 35(17): 205–214. (in Chinese)
- [14] 赵德安, 刘晓洋, 孙月平, 等. 基于机器视觉的水下河蟹识别方法[J/OL]. 农业机械学报, 2019, 50(3): 151–158.
- ZHAO Dean, LIU Xiaoyang, SUN Yueping, et al. Detection of underwater crabs based on machine vision [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(3): 151–158. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20190316&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2019.03.016. (in Chinese)
- [15] 林相泽, 朱赛华, 张俊媛, 等. 基于迁移学习和 Mask R-CNN 的稻飞虱图像分类方法[J/OL]. 农业机械学报, 2019, 50(7): 201–207.
- LIN Xiangze, ZHU Saihua, ZHANG Junyuan, et al. Rice planthopper image classification method based on transfer learning and Mask R-CNN [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(7): 201–207. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20190721&flag=1. DOI: 10.6041/j.issn.1000-1298.2019.07.021. (in Chinese)
- [16] DEBOJIT B, SU H B, WANG C Y, et al. An automatic traffic density estimation using single shot detection (SSD) and MobileNet-SSD [J]. Physics and Chemistry of the Earth, 2019, 110: 176–184.
- [17] HOWARD A, SANDLER M, CHU G, et al. Searching for MobileNetV3 [J]. arXiv Preprint. arXiv:1905.02244, 2019.
- [18] 邹秀容, 潘磊庆, 屠康, 等. 鸡种蛋孵化品质无损检测的研究进展[J]. 食品工业科技, 2010, 31(2): 342–344, 347.
- ZOU Xiurong, PAN Leiqing, TU Kang, et al. Research progresses in non-destructive measurements on incubation quality of eggs [J]. Science and Technology of Food Industry, 2010, 31(2): 342–344, 347. (in Chinese)
- [19] 曾科. 基于深度学习中 SSD_Mobilenet 的目标检测[D]. 长沙: 湖南师范大学, 2019: 27–44.
- ZENG Ke. Object detection based on SSD_Mobilenet in deep learning [D]. Changsha: Hunan Normal University, 2019: 27–44. (in Chinese)
- [20] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: efficient. convolutional neural networks for mobile vision applications [J]. arXiv preprint. arXiv:1704.04861, 2017.
- [21] 郑冬, 李向群, 许新征. 基于轻量化 SSD 的车辆及行人检测网络[J]. 南京师范大学学报(自然科学版), 2019, 42(1): 73–81.
- ZHENG Dong, LI Xiangqun, XU Xinzhen. Vehicle and pedestrian detection model based on lightweight SSD [J]. Journal of Nanjing Normal University (Natural Science Edition), 2019, 42(1): 73–81. (in Chinese)
- [22] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: inverted residuals and linear bottlenecks [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510–4520.
- [23] XU B, WANG N, CHEN T, et al. Empirical evaluation of rectified activations in convolutional network [J]. arXiv Preprint arXiv: 1505.00853, 2015.
- [24] 许景辉, 邵明焯, 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/OL]. 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 convolutional neural network [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2): 230–236, 253. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=2002025&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2020.02.025. (in Chinese)