doi:10.6041/j.issn.1000-1298.2021.10.031

基于知识蒸馏的叠层笼养蛋鸡行为识别模型研究

方　鹏　郝宏运　王红英
(中国农业大学工学院, 北京 100083)

摘要: 为了实现叠层笼养环境下蛋鸡行为的识别检测,构建了一种基于多教师模型融合的知识蒸馏蛋鸡行为识别模型,用多个教师模型融合指导学生网络训练。对基于 Faster R-CNN 框架的蛋鸡行为识别模型的特征提取网络进行知识蒸馏,以结构较复杂的 ResNeXt、Res2Net 和 HRNet 网络为教师网络,以结构较简单的 ResNet 34 网络为学生网络,通过知识蒸馏训练蛋鸡行为识别模型。试验结果表明,特征提取网络经过知识蒸馏后,蛋鸡行为识别模型性能得到显著提升,与特征提取网络未经过知识蒸馏的识别模型相比,模型准确率、平均精确度、召回率分别从 93.6%、78.7%、86.2% 提升至 96.6%、89.9%、94.6%;学生模型经过知识蒸馏后基本达到了教师模型的性能水平,而模型参数量和模型计算量比教师模型降低了 32% 和 33%,模型推理时间降低了 66%。本研究提出的知识蒸馏模型通过较简单的网络结构获得了高精度的识别模型,为蛋鸡行为识别模型在小型嵌入式设备的部署提供了可能。

关键词: 蛋鸡; 动物行为; 深度学习; 知识蒸馏; 模型融合
中图分类号: S818.9　　**文献标识码**: A　　**文章编号**: 1000-1298(2021)10-0300-07　　**OSID**:

Behavior Recognition Model of Stacked-cage Layers Based on Knowledge Distillation

FANG Peng　HAO Hongyun　WANG Hongying
(*College of Engineering*, *China Agricultural University*, *Beijing* 100083, *China*)

Abstract: Animal behavior is closely related to animal welfare and health. It is an important means to evaluate animal welfare and health status through the identification and detection of animal behavior. In order to achieve the recognition and detection of layer behavior in the stacked-cage system, a knowledge distillation layer behavior recognition model based on ensemble of multi-teacher model was constructed, and the student network training was guided by multiple teacher model. The knowledge distillation method was applied to the feature extraction network of layer behavior recognition model based on Faster R-CNN framework. Taking ResNeXt, Res2Net and HRNet networks as teacher networks and ResNet 34 networks as student networks, the layer behavior recognition model was trained through knowledge distillation method. The experimental results showed that the performance of layer behavior recognition model was significantly improved. Compared with the recognition model without knowledge distillation, the accuracy, average precision and recall of the model were improved from 93.6%, 78.7% and 86.2% to 96.6%, 89.9% and 94.6%, respectively. After knowledge distillation, the student model basically reached the performance level of the teacher model, while the number of parameters and computation were reduced 32% and 33% than the teacher model, and the inference time of the model was reduced by 66%. The knowledge distillation model proposed obtained a high-precision recognition model through a relatively simple network structure, which provided the possibility for the deployment of layer behavior recognition model in edge embedded devices.

Key words: layer; animal behavior; deep learning; knowledge distillation; model fusion

收稿日期: 2021-05-16　修回日期: 2021-07-20
基金项目: 国家重点研发计划项目(2017YFE0122200)
作者简介: 方鹏(1993—),男,博士生,主要从事畜禽养殖技术与装备研究,E-mail: fangpeng@cau.edu.cn
通信作者: 王红英(1966—),女,教授,博士生导师,主要从事畜禽养殖技术与装备研究,E-mail: hongyingw@cau.edu.cn

0　引言

动物行为直接反映动物机体对环境的适应程度，不同的行为方式反映动物自身的不同状态，是动物福利评估的重要指标[1-2]，而畜禽生产中动物行为的突然改变往往是动物机体发出的预警信号[3]。因此，实现对动物行为的识别检测对于评估动物福利及健康状态具有重要意义。

相比于奶牛、猪等大体型动物，蛋鸡养殖具有群体大、养殖密度高的特点，其个体行为的识别相对困难[4]。目前，人们主要基于机器视觉技术对蛋鸡行为的识别、分类进行了研究。LEROY 等[5]对蛋鸡轮廓图像进行椭圆拟合，建立点分布模型，可对单只蛋鸡的站立、行走和抓挠行为进行识别。劳凤丹等[2,6]针对鸡只的 RGB 图像和深度图像，基于贝叶斯分类方法实现了对单只蛋鸡行为的识别检测，可对鸡只的采食、运动、饮水等 10 种行为进行有效识别，大多数行为的识别准确率在 90% 以上。MEHADIZADEH 等[7]对鸡只采食过程中的头部位移、喙部张开速度及闭合速度、喙部张开加速度和闭合加速度等参数的自动检测进行了研究，对鸡只采食行为进行了深入的生物力学研究。上述基于机器学习技术的家禽行为识别技术虽然能达到较高的准确率，但由于需人工提取图像的特征参数，存在模型泛化性、鲁棒性差，特征提取困难的缺点。

深层卷积神经网络的兴起为动物行为的精确识别提供了新思路。由于深层卷积神经网络能够通过大量样本对数据特征进行自主学习，尤其对图像具有极强的表征能力，可以自动提取图像特征，在目标检测和分类领域均有优异表现，在动物行为检测方面也有相关研究。文献[8-11]通过深层卷积神经网络对鸡只的行为检测和分类技术进行了研究并取得较高的检测准确率。然而，深层卷积神经网络的高准确率是基于更深、更广和更复杂的网络结构实现的，网络性能不断提升的同时网络模型的复杂度和参数量呈几何级数增加，复杂的模型对设备性能要求太高，模型的实时性无法保证，限制了深度学习技术在畜禽生产实际中的应用，因此需在保证模型性能的前提下尽量减少模型参数，对模型进行压缩。

HINTON 等[12]提出的知识蒸馏理论表明，通过用一个或多个复杂、准确的大型网络来指导简单、小型网络训练的方式可以显著提升小型网络的性能。为实现叠层笼养环境下蛋鸡行为的识别分类，本文以 Faster R-CNN[13]深度学习模型为基础，基于知识蒸馏理论，构建一种基于多教师模型融合的知识蒸馏蛋鸡行为识别模型，用较简单的卷积神经网络结构获得较高的性能，降低网络对设备性能的要求，为模型的在线实时部署应用提供可能。

1　图像采集与数据集建立

选择北京德青源农业科技股份有限公司的蛋鸡养殖场作为图像采集地点，该养殖场为全封闭的 8 层叠层笼养蛋鸡舍，每笼饲养“京红”蛋鸡 6 只左右，每栋鸡舍饲养 11 万只蛋鸡，蛋鸡周龄为 34 周。

蛋鸡图像的采集由立式三脚架搭载彩色数字相机完成，相机型号为 Sony XCG-240C，分辨率为 1 920 像素×1 200 像素，匹配焦距 6 mm 的 Ricoh FL-CC0614A-2M 型定焦镜头，拍摄时相机曝光时间设置为 100 ms。将工业相机正对笼门位置拍摄，摄像头视野范围正好覆盖两个笼位，对舍内 200 个笼位的鸡只进行图像采集。采集的图像如图 1 所示。



图 1　鸡只图像

Fig. 1　Layer image

图像经过随机旋转、颜色变换、添加高斯噪声的方式增强后，人工挑选出 1 000 幅蛋鸡图像建立样本集。随后，在 Labelme 图像标注工具中用矩形工具将鸡只标注为“feeding（采食）”和“resting（休息）”两类，制作成 COCO（Common objects in context）格式的数据集。头部伸入食槽或者有靠近食槽动作的鸡只，标注为“feeding”，头部仰起呈站立姿态的鸡只则标注为“resting”。随机选取 70% 样本集图像（700 幅）作为训练集，用于模型的训练，选取 20%（200 幅）作为验证集，用于模型参数调优，选取 10%（100 幅）图像作为测试集，用于评估最终模型的识别能力。在训练集图像中，共有 4 552 个标注样本，其中鸡只采食行为的标注样本为 2 134 个，鸡只休息行为的标注样本为 2 418 个，二者之间比例接近 1∶1，样本分类较均衡。

2　基于 Faster R-CNN 的蛋鸡行为识别网络建立

本文选择在 Faster R-CNN 框架上构建蛋鸡行为识别网络，其结构如图 2 所示。Faster R-CNN 网络是目标检测领域运用最广泛的模型之一，网络由特征提取网络、区域生成网络及区域卷积神经网络 3 部分组成。特征提取网络主要负责提取输入图像特征并共享给后续的区域生成网络和区域卷积神经

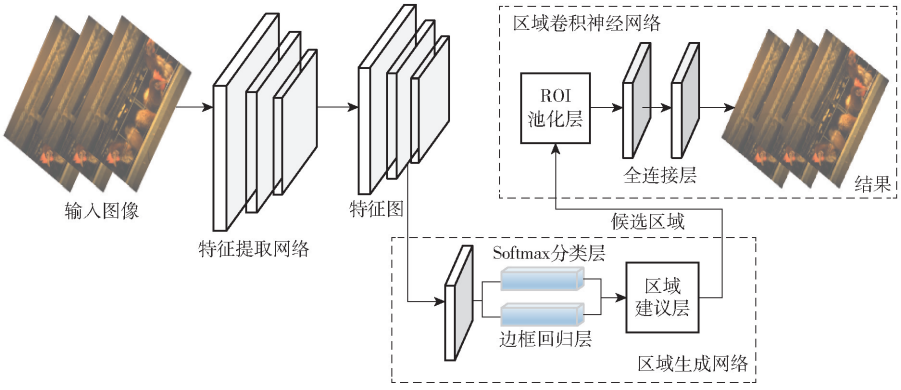

图 2 Faster R - CNN 网络结构图

Fig. 2 Network structure diagram of Faster R - CNN

网络;区域生成网络通过对特征提取网络输入的特征图做进一步处理,输出若干可能存在待检测目标的区域,并输入后续的区域卷积神经网络判定目标类别,实现目标的定位和分类。

知识蒸馏是模型压缩的一种手段,其核心思想是利用一个或多个复杂、参数多、准确的大型网络来指导训练一个简单、参数较少的小型网络,将大型网络学习到的"知识"传递给小型网络[14-15],其中复杂、参数多的大型网络称为教师网络,精度高但参数量大,对设备性能要求高,很难在嵌入式小型设备中部署;简单、参数较少的小型网络称为学生网络,参数少,容易部署,但单独训练时模型精确度不高,很难满足实际应用需求。通过知识蒸馏,可以显著提升小型网络的性能,在参数量较少的情况下使其拥有和复杂网络相近或超越复杂网络的性能。

以图像分类任务为例,神经网络通常会在全连接层之后连接一个 Softmax 输出层,将全连接层的输出向量转化为一个概率向量[16],该概率向量表示当前样本分别属于每一类的概率,每类的概率 p_i 计算公式为

$$p_i = \frac{\exp(z_i)}{\sum_j \exp(z_j)} \tag{1}$$

式中 j——分类的总类别数

z_j——全连接层输出的每类的 logit 值

z_i——当前类的 logit 值

而知识蒸馏理论通过引入一个参数 T,使 Softmax 层输出一个更加平缓的概率分布,得到一个软化后的概率向量 $\boldsymbol{q}$,每类的概率 q_i 计算公式为

$$q_i = \frac{\exp\frac{z_i}{T}}{\sum_j \exp\frac{z_j}{T}} \tag{2}$$

式中,T 为温度系数,T 越大,对应的概率分布越平缓,则意味着更多"暗知识"被蒸馏出来,当 $T=1$ 时,输出的是没有经过软化的概率分布。知识蒸馏通过引入软标签(Soft label),将数据集中离散的标签属性转换成连续的概率分布,提取教师网络中的"暗知识",并将其传递给学生网络,从而提升学生网络模型性能[17]。

3 多教师模型融合的知识蒸馏蛋鸡行为识别模型构建

本文对 Faster R - CNN 网络的特征提取网络利用知识蒸馏进行压缩,利用教师网络指导学生网络训练,通过"暗知识"的传递,提升学生网络性能。现有研究表明,采用多个教师模型诱导训练的方式可以更有效提升学生网络性能,且当教师网络和学生网络结构较相似时,往往能使学生模型获得较大的性能提升[18-20]。因此,本文以参数量大,较复杂的 ResNeXt[21]、Res2Net[22]、HRNet[23] 网络为教师网络,以结构较简单的 ResNet 34 为学生网络,通过知识蒸馏训练蛋鸡行为识别网络。

首先对教师网络进行训练。与普通神经网络训练方式相同,利用蛋鸡行为数据样本和相应的样本标签分别对 3 个教师网络进行训练,得到 3 个性能强大的复杂模型。随后,训练好的教师模型中的 logits 输出后除以 T 并做 Softmax 计算,得到软化后的预测概率,3 个教师模型的软化预测概率取平均值后作为最终的软标签值。最后对学生网络进行训练。学生网络的训练分两部分,一是采用正常的训练方式得到 logits 输出,做 Softmax 计算后得到预测值,将此预测值与样本真实标签比较,用交叉熵损失函数衡量二者之间的差异;二是将输出的 logits 值除以 T 后做 Softmax 计算得到软化的预测概率向量,将此预测概率向量与教师网络输出的软标签值比较,采用相对熵损失函数衡量两个概率分布的差异。因此,采用混合损失函数[16,24]来表征知识蒸馏过程中的损失,其计算公式为

$$L=\lambda T^2\mathrm{KL}(n_1,n_2)+(1-\lambda)\mathrm{CE}(m,g_{true}) \quad (3)$$

式中　KL——相对熵函数

CE——交叉熵函数

n_1——3 个教师网络经过蒸馏后的平均输出

n_2——学生网络蒸馏后的输出

m——学生网络未经过蒸馏的输出

g_{true}——数据集的真实标签

λ——比例系数，当 λ 为 0 时，相当于网络没有经过蒸馏

本文选择 $T=2$、$\lambda=0.7$ 作为知识蒸馏网络的超参数配置。知识蒸馏训练架构图如图 3 所示。图中 t 为任意常数。

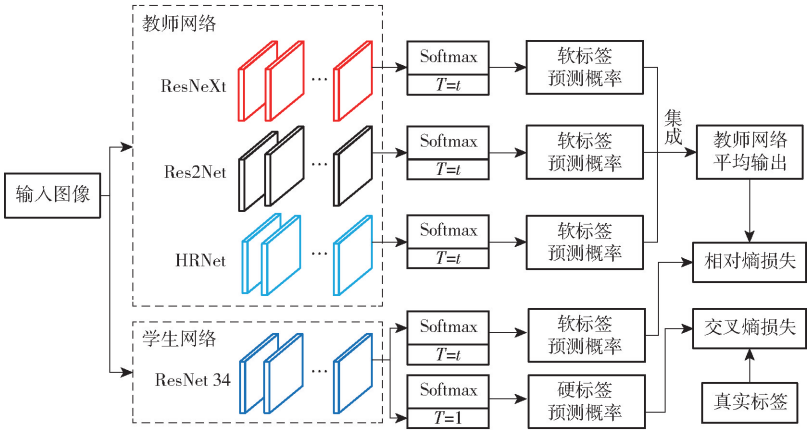

图 3　知识蒸馏训练架构图

Fig. 3　Knowledge distillation training framework

4　结果与分析

4.1　试验条件及参数设置

试验在 Ubuntu 18.04 系统中进行，试验用计算机处理器为 Intel（R） Core（TM） i7 - 9700K，主频 3.6 GHz，内存 16 GB，显卡为 NVIDIA GeForce RTX 2080（16 GB），使用 GPU 加速计算，在 Python 语言环境中选择 Pytorch 框架实现网络模型的搭建、训练和调试，使用 OpenMMLab 开放的预训练模型作为初始输入权重，按表 1 对模型参数进行初始化，采用随机梯度下降法对蛋鸡行为识别网络进行训练。训练迭代 120 个周期，每 10 个周期保存一次权重参数，取精度最高的权重为最终模型。

表 1　Faster R - CNN 初始化训练参数

Tab. 1　Training parameters for Faster R - CNN

参数	数值
批尺寸	4
初始学习率	0.001
学习率衰减指数	0.1
动量	0.9
训练迭代周期数	120
权值衰减指数	0.000 1

4.2　模型测试结果分析

采用不同的图像特征提取网络进行蛋鸡行为检测试验，分别为 3 个教师网络（ResNeXt、Res2Net、HRNet）、由 3 个教师网络融合蒸馏的 ResNet 34 网络（KD ResNet 34）及未经知识蒸馏的 ResNet 34 网络。模型训练完成后以准确率、平均精确度、召回率、模型参数量、浮点运算次数及单幅图像检测耗时作为评价模型性能的指标，对比结果如表 2 所示。结果表明，知识蒸馏显著提升了蛋鸡行为识别模型的性能。3 个教师网络具有相似的模型性能，模型平均准确率为 95.93%，平均精确度为 89.2%，平均召回率为 94.10%。未经过知识蒸馏的 ResNet 34 模型准确率（A）、平均精确度（P）和召回率（R）分别为 93.6%、78.7% 和 86.2%，而 KD ResNet 34 模型的准确率、平均精确度和召回率分别为 96.6%、89.9% 和 94.6%，相较于未经过蒸馏的网络，3 个指标均有较大幅度的提高，尤其是平均精确度和召回率，分别提高了 11.2、8.2 个百分点。学生网络经过 3 个教师网络的指导训练，学习到了教师网络提取的“暗知识”，性能得到很大提升，学生网络性能基本达到甚至超越了教师网络的性能。

模型参数量、模型计算量衡量的是模型的复杂程度，模型越复杂，则其部署应用的难度越大，所需的设备性能要求越高。由表 2 可知，3 个教师网络模型复杂程度相似，模型平均参数量为 5.58×10^7，模型平均浮点运算次数达 2.88×10^{11}。KD ResNet 34 模型性能基本达到了教师网络的性能水平，而其模型复杂程度却大大降低，模型参数量为 3.816×10^7，模型浮点运算次数为 $1.916\,9\times10^{11}$，与教师网络相比，分别降低了 32% 和 33%。模型复杂程度降低意味着模型对设备性能的依赖程度降低，模型将有可能在一些小型的嵌入式设备中部署运用。同

表 2 不同模型性能对比

Tab. 2 Performance comparison of different models

特征提取网络	准确率/%	平均精确度/%	召回率/%	参数量	浮点运算次数	单幅图像检测耗时/s
ResNeXt	96.2	88.8	93.4	5.976×10^7	$2.864\,9\times10^{11}$	0.206
Res2Net	95.5	89.0	94.0	6.079×10^7	$2.932\,7\times10^{11}$	0.243
HRNet	96.1	89.8	94.9	4.688×10^7	$2.850\,1\times10^{11}$	0.213
ResNet 34	93.6	78.7	86.2	3.816×10^7	$1.916\,9\times10^{11}$	0.069
KD ResNet 34	96.6	89.9	94.6	3.816×10^7	$1.916\,9\times10^{11}$	0.068

时,与教师网络相比,由于学生网络有更简单的网络结构和更少的参数,模型的推理时间大大降低,在相同的测试环境中,经过知识蒸馏的学生网络单幅图像的检测耗时为 0.068 s,显著低于教师网络,模型推理时间降低了 66%。模型推理时间的降低增加了模型在边缘设备在线实时部署的可能性。

图 4 为特征提取网络经过知识蒸馏和未经过知识蒸馏的蛋鸡行为识别模型对同一幅图像的检测结果对比。由图可知,经过知识蒸馏的蛋鸡行为识别模型基本能对鸡只行为作出准确判断,目标定位和分类均较为准确,而未经过知识蒸馏的模型存在较多误检测、重复检测及漏检测的情况,模型的精度和泛化性均不如经过知识蒸馏的模型。显然,知识蒸馏显著提升了检测模型的性能。

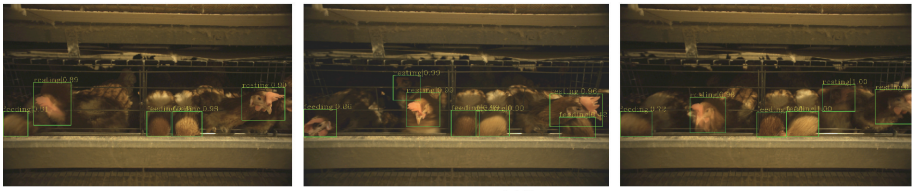

(a) KD ResNet 34网络



(b) ResNet 34网络

图 4 模型检测结果对比

Fig. 4 Comparison of model test results

网络在训练过程中损失函数的变化情况可以在一定程度上反映训练完成的模型性能。图 5 为经过知识蒸馏和未经过知识蒸馏网络在训练过程中的损失值变化曲线。由图 5 可知,两个网络损失值均在训练开始后很短时间内下降到较低值。随着训练的继续,网络损失持续降低,当训练迭代到一定次数后,损失开始随迭代次数的增加而缓慢下降,经过 16 000 次左右的迭代后,损失值变化趋于平缓,几乎不再下降,网络实现收敛。可以看到,网络收敛后,经过知识蒸馏的识别模型最终损失值稳定在 0.3 左右,而未经过蒸馏的模型最终损失值在 0.5 左右,知识蒸馏降低了网络的训练损失。

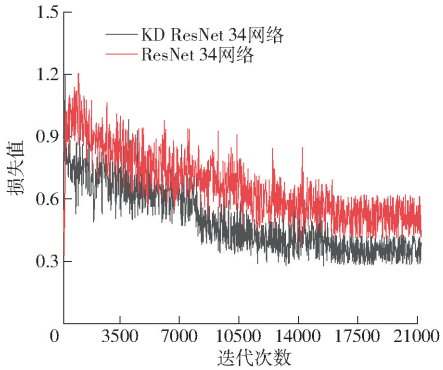

图 5 网络训练损失值变化曲线

Fig. 5 Change curves of network training loss

图 6 为模型经过测试后得到的 $P-R$ 曲线图。曲线与横、纵坐标围成的区域越大,则说明网络性能

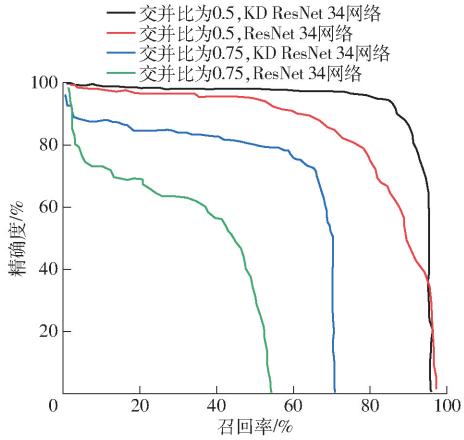

图 6 蒸馏前后网络 $P-R$ 曲线对比

Fig. 6 Comparison of network $P-R$ curves

越好，由图 6 可知，在不同交并比下，KD ResNet 34 网络的 $P-R$ 曲线几乎将 ResNet 34 网络的 $P-R$ 曲线完全包围，说明经过知识蒸馏的网络的性能显著优于未经过蒸馏的 ResNet 34 网络。

4.3　类激活热力图可视化分析

GRAD－CAM 算法[25]可以用来对网络进行可视化分析，直观展示网络在进行预测时重点关注的图像区域，从而对不同网络的性能作出直观判断，更加清晰地展现知识蒸馏对模型性能带来的提升。对 Faster R－CNN 的不同特征提取网络的输出进行可视化，本文研究中涉及的 Res2Net、HRNet、ResNeXt 及 ResNet 网络均有 4 个阶段的输出特征图进入后续 FPN 网络进行融合，因此输出了主干网络 4 个阶段的特征类激活热力图。

图 7 为不同网络 4 个阶段输出特征的热力图。图中红色、黄色覆盖的区域即为卷积层提取特征时关注的重点区域，可以看出在网络的第 1 阶段和第 2 阶段，网络提取的特征没有针对性，只是对整个图像的全部特征进行提取，随着卷积层的加深，网络提取特征的重点开始倾向于鸡只轮廓区域，尤其集中在鸡头部位，最后一个阶段的特征热力图表明，网络已经基本实现了背景和目标的区分，提取特征的重点几乎全部集中在鸡只头部和颈部位置。对比不同的网络特征热力图可以发现，经过知识蒸馏的模型（KD ResNet 34）与 3 个教师网络的特征检测结果相似，提取的特征均能很好地覆盖鸡只轮廓部位，而未经过蒸馏的网络，热力值高的区域均集中在图像上、下部区域的食槽部位，说明网络没有很好地提取到鸡只的特征，最终模型的识别效果较差。

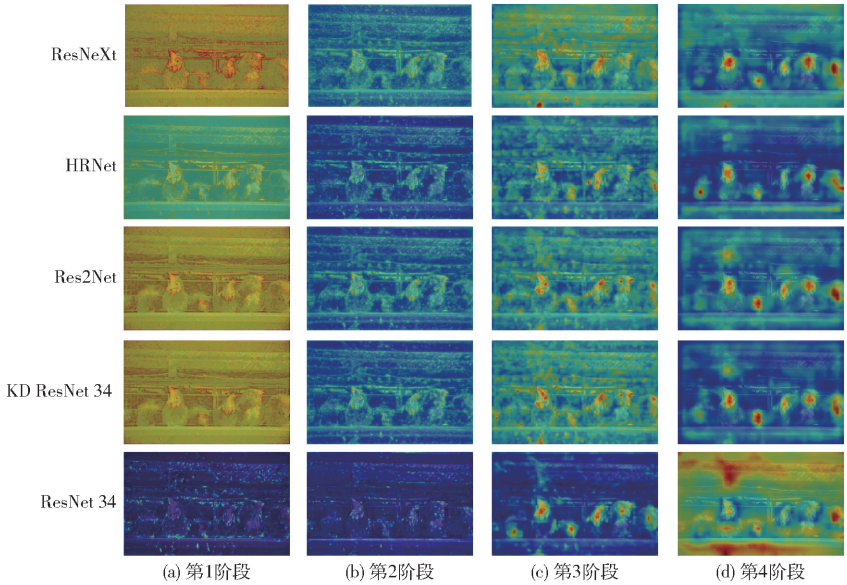

图 7　不同网络不同阶段的热力图

Fig. 7　Heat maps of different networks in different stages

5　结论

（1）为实现叠层笼养环境下蛋鸡行为的识别分类，本文以 Faster R－CNN 深度学习模型为基础，构建了蛋鸡行为识别模型。同时，针对模型参数量大、结构复杂、对设备性能要求高、无法在线实时部署的缺陷，基于知识蒸馏理论，对模型进行了压缩，构建了一种基于多教师模型融合的知识蒸馏蛋鸡行为识别模型。

（2）特征提取网络（ResNet 34）经过知识蒸馏后，基于 Faster R－CNN 框架的蛋鸡行为识别模型性能得到显著提升，模型准确率、平均精确度、召回率分别为 96.6%、89.9%、94.6%，与未经过知识蒸馏的模型相比，分别提高了 3.0、11.2、8.4 个百分点。

（3）经过知识蒸馏后，模型性能基本达到了教师模型的性能水平，而模型复杂程度却大大降低，与教师模型相比，模型参数量和模型计算量分别降低了 32% 和 33%，模型推理时间减少了 66%。

参　考　文　献

[1] APPLEBY M C, HUGHES B O, HOGARTH G S. Behavior of laying hens in a deep litter house[J]. British Poultry Science, 1989, 30(3): 545－553.

[2] 劳凤丹, 滕光辉, 李军, 等. 机器视觉识别单只蛋鸡行为的方法[J]. 农业工程学报, 2012,28(24):157－163.
LAO Fengdan, TENG Guanghui, LI Jun, et al. Behavior recognition method for individual laying hen based on computer vision [J]. Transactions of the CSAE, 2012,28(24):157－163. (in Chinese)

[3] CANGAR Ö, LEROY T, GUARINO M, et al. Automatic real-time monitoring of locomotion and posture behaviour of pregnant cows prior to calving using online image analysis[J]. Computers and Electronics in Agriculture, 2008, 64(1): 53 - 60.
[4] AYDIN A, CANGAR O, OZCAN S E, et al. Application of a fully automatic analysis tool to assess the activity of broiler chickens with different gait scores[J]. Computers and Electronics in Agriculture, 2010, 73(2): 194 - 199.
[5] LEROY T, VRANKEN E, VAN BRECHT A, et al. A computer vision method for on-line behavioral quantification of individually caged poultry[J]. Transactions of the American Society of Agricultural and Biological Engineers, 2006, 49(3): 795 - 802.
[6] 劳凤丹, 杜晓冬, 滕光辉. 基于深度图像的蛋鸡行为识别方法[J/OL]. 农业机械学报, 2017, 48(1):155 - 162.
LAO Fengdan, DU Xiaodong, TENG Guanghui. Automatic recognition method of laying hen behaviors based on depth image processing[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(1):155 - 162. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=20170120&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2017.01.020. (in Chinese)
[7] MEHDIZADEH S A, NEVES D P, TSCHARKE M, et al. Image analysis method to evaluate beak and head motion of broiler chickens during feeding[J]. Computers and Electronics in Agriculture, 2015, 114: 88 - 95.
[8] 王凯, 姜昊昊, 吕艳, 等. 基于深度学习的笼养蛋鸡行为实时检测方法[J]. 中国农业大学学报, 2019, 24(11): 123 - 133.
WANG Kai, JIANG Wuhao, LÜ Yan, et al. Real-time detection method for cage laying hens' behavior based on deep learning [J]. Journal of China Agricultural University, 2019, 24(11): 123 - 133. (in Chinese)
[9] LI G, ZHAO Y, CHESSER D, et al. Image processing for analyzing broiler feeding and drinking behaviors[C]//2019 ASABE Annual International Meeting, 2019.
[10] PU H, LIAN J, FAN M. Automatic recognition of flock behavior of chickens with convolutional neural network and Kinect sensor[J]. International Journal of Pattern Recognition and Artificial Intelligence, 2018,32(7):1850023.
[11] WANG J, WANG N, LI L, et al. Real-time behavior detection and judgment of egg breeders based on YOLOv3[J]. Neural Computing and Applications, 2020, 32(10): 5471 - 5481.
[12] HINTON G, VINYALS O, DEAN J. Distilling the knowledge in a neural network[J]. Computer Science, 2015, 14(7): 38 - 39.
[13] REN S, HE K, GIRSHICK R, et al. Faster R - CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137 - 1149.
[14] 周苏, 易然, 郑淼. 基于知识蒸馏的车辆可行驶区域分割算法研究[J]. 汽车技术, 2020(1):1 - 5.
ZHOU Su, YI Ran, ZHENG Miao. Research on drivable area segmentation algorithms based on knowledge distillation[J]. Automobile Technology,2020(1):1 - 5. (in Chinese)
[15] 李亮德, 王秀娟, 康孟珍, 等. 基于语义融合与模型蒸馏的农业实体识别[J]. 智慧农业(中英文), 2021, 3(1):118 - 128.
LI Liangde, WANG Xiujuan, KANG Mengzhen, et al. Agricultural named entity recognition based on semantic aggregation and model distillation[J]. Smart Agriculture, 2021, 3(1):118 - 128. (in Chinese)
[16] 倪建功, 李娟, 邓立苗, 等. 基于知识蒸馏的胡萝卜外观品质等级智能检测[J]. 农业工程学报, 2020, 36(18): 181 - 187.
NI Jiangong, LI Juan, DENG Limiao, et al. Intelligent detection of appearance quality of carrot grade using knowledge distillation[J]. Transactions of the CSAE,2020, 36(18):181 - 187. (in Chinese)
[17] 凌弘毅. 基于知识蒸馏方法的行人属性识别研究[J]. 计算机应用与软件, 2018, 35(10): 181 - 184.
LING Hongyi. Pedestrian attribute recognition based on knowledge distillation[J]. Computer Application and Software, 2018, 35(10): 181 - 184. (in Chinese)
[18] YOU S, XU C, XU C, et al. Learning from multiple teacher networks[C]//The ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2017:1285 - 1294.
[19] LIU Yuang, ZHANG Wei, WANG Jun. Adaptive multi-teacher multi-level knowledge distillation[J]. Neurocomputing, 2020, 415: 106 - 113.
[20] CHEN Guobin, CHOI Wongun, YU Xiang, et al. Learning efficient object detection models with knowledge distillation[C]// International Conference on Neural Information Processing Systems, 2017: 742 - 751.
[21] XIE S, GIRSHICK R, DOLLÁR P, et al. Aggregated residual transformations for deep neural networks[C]//The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 5987 - 5995.
[22] GAO S H, CHENG M M, ZHAO K, et al. Res2Net: a new multi-scale backbone architecture[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 43(2): 652 - 662.
[23] SUN K, XIAO B, LIU D, et al. Deep high-resolution representation learning for human pose estimation[C]//The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2019: 5686 - 5696.
[24] 张彤彤, 董军宇, 赵浩然, 等. 基于知识蒸馏的轻量型浮游植物检测网络[J].应用科学学报, 2020, 38(3): 367 - 376.
ZHANG Tongtong, DONG Junyu, ZHAO Haoran, et al. Lightweight phytoplankton detection network based on knowledge distillation[J]. Journal of Applied Science,2020, 38(3): 367 - 376. (in Chinese)
[25] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad - CAM: visual explanations from deep networks via gradient-based localization[J]. International Journal of Computer Vision, 2020, 128(2): 336 - 359.