doi:10.6041/j.issn.1000-1298.2025.01.005

基于彩色与热红外图像信息融合的肉鸡死鸡识别方法

郝宏运[1]　姜　伟[1]　罗　升[2]　孙宪法[3]　王粮局[1]　王红英[1]
(1. 中国农业大学工学院, 北京 100083; 2. 江苏省农业机械试验鉴定站, 南京 210017;
3. 山东民和牧业股份有限公司, 烟台 264000)

摘要: 为了提高规模化肉鸡养殖场中肉鸡死鸡识别的精度,基于彩色图像和热红外图像,分别提出了基于两阶段与单阶段的肉鸡死鸡检测方法。在两阶段方法中,首先使用 YOLO v11 - seg 网络对彩色图像中肉鸡进行分割,获取肉鸡掩膜坐标;然后提取单只肉鸡热红外图像,使用 YOLO v8 - cls 分类网络对单只肉鸡热红外图像进行分类。在单阶段方法中,基于彩色图像和配准热红外图像分别构建了 G 通道替换融合图像、加权融合图像、小波变换融合图像以及频域变换融合图像,使用多源融合图像数据集基于 YOLO v11s 目标检测网络构建了肉鸡死鸡检测模型。结果表明,两阶段肉鸡死鸡检测方法中,肉鸡实例分割平均精确率为 94.2%,单只肉鸡热红外图像分类准确率为 99.4%。单阶段肉鸡死鸡检测方法中,基于小波变换融合图像构建的肉鸡死鸡检测模型获得了最高的检测精度,检测平均精确率为 93.0%。两种方法相比,单阶段检测方法在公共测试集上精确率更高,为 92.3%,推理速度更快(6.1 ms/f),单模型部署更加简单。对肉鸡热红外图像温度分布分析表明,低周龄肉鸡与高周龄肉鸡的体表温度分布具有明显差异。提出的肉鸡死鸡检测方法,能够在高密度养殖下的恶劣成像环境中对肉鸡死鸡实现准确识别,为其他畜禽死亡检测提供了技术参考。

关键词: 肉鸡死鸡; 热红外图像; 彩色图像; 图像配准; YOLO v11
中图分类号: S858.3; TP391.41　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)01-0047-09　　**OSID**:

Detection of Dead Broilers Based on Fusion of Color and Thermal Infrared Image Information

HAO Hongyun[1]　JIANG Wei[1]　LUO Sheng[2]　SUN Xianfa[3]　WANG Liangju[1]　WANG Hongying[1]
(1. *College of Engineering*, *China Agricultural University*, *Beijing* 100083, *China*
2. *Jiangsu Agricultural Machinery Testing and Appraisal Station*, *Nanjing* 210017, *China*
3. *Shandong Minhe Animal Husbandry Co.*, *Ltd.*, *Yantai* 264000, *China*)

Abstract: In order to improve the accuracy of dead broiler detection in large-scale broiler farms, based on color images and thermal infrared images, two-stage and one-stage dead broiler detection methods for broilers were proposed, respectively. In the two-stage method, the YOLO v11 - seg network was firstly used to segment broilers in color images to obtain broiler mask coordinates; then individual broiler thermal infrared images were extracted and classified by using the YOLO v8 - cls classification network. In the one-stage method, G-channel replacement fusion images, weighted fusion images, wavelet transform fusion images, and frequency domain transform fusion images were constructed based on color images and registered thermal infrared images. Multi-source fusion image datasets were used to build a dead broiler detection model based on the YOLO v11s object detection network. The results showed that in the two-stage dead broiler detection method, the mAP of broiler instance segmentation was 94.2%, and the classification accuracy of individual broiler thermal infrared images was 99.4%. In the one-stage dead broiler detection method, the model built based on wavelet transform fusion images achieved the highest detection accuracy, with mAP of 93.0%. Compared with the two-stage method, the one-stage detection method had a higher precision rate of 92.3% on the public test set, faster inference speed (6.1 ms/f), and easier to be deployed. Analysis of the temperature distribution of individual broiler

收稿日期: 2024 - 10 - 28　修回日期: 2024 - 11 - 25
基金项目: 科技创新 2030—"新一代人工智能"重大项目(2021ZD0113804 - 3)
作者简介: 郝宏运(1997—),男,博士生,主要从事畜牧养殖技术与装备研究,E-mail: 2496995286@qq.com
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

thermal infrared images indicated that there were significant differences in body surface temperature distribution between low-age and high-age broilers. The dead broiler detection method proposed can accurately identify dead broilers in the harsh imaging environment under high-density breeding, and it can provide a technical reference for the death detection of other livestock and poultry.

Key words: dead broiler; thermal infrared image; color image; image registration; YOLO v11

0 引言

鸡肉是我国第二大肉类产品,其中白羽肉鸡占我国鸡肉产量的 58%,占畜禽肉类产量的 16%,其规模化养殖比重更达到了 95% 以上[1]。商品白羽肉鸡在我国主要采用叠层笼养的养殖方式。规模化叠层笼养具有空间利用率高、养殖密度大、自动化程度高、方便管理等优点。随着现代畜禽养殖业的发展,规模化商品养殖场已基本实现机械化、自动化,然而死鸡巡检仍是养殖过程中迫切需要自动化的环节。死亡家禽在养殖舍中会逐渐腐烂,传染疾病导致家禽福利降低,通常需要养殖人员对所有鸡笼进行逐个巡检并剔除死鸡。然而由于规模化商品养鸡场养殖规模庞大,人工巡检耗时费力,对高层鸡笼巡检又有一定的危险性[2]。

精准畜禽技术使用传感器技术对畜禽的状态进行监测,为自动化养殖提供了新的方案。研究者使用视觉传感器技术获取畜禽的视频或图像,通过图像处理或深度学习技术来提取畜禽疾病关键特征,对畜禽的健康状态进行自动检测和分类[3-7]。热红外成像是一种利用物体发出的红外辐射进行成像的技术,在稳定环境下,能够获取反映物体表面温度的图像,在农业中具有广泛的应用[8-11]。畜禽动物在感染疾病和发生生理异常时,通常会表现出身体部位温度的异常,研究者使用热红外成像技术获取动物眼睛、颈部、腹部、乳房、腿部部位的温度图像,对畜禽健康异常进行预警与检测[12-15]。

在规模化叠层笼养肉鸡舍中,彩色相机受光照环境的影响,获取的图像往往出现过曝、噪点以及细节模糊等问题。肉鸡死亡后,不仅会在外形上表现出差异,其体表温度也会迅速下降产生温度差异,热红外图像能够反映肉鸡的体表温度信息,在死亡肉鸡的自动识别中具有巨大的潜力。因此,本文结合彩色图像与热红外图像的信息优势,提出基于热红外与可见光图像信息融合的肉鸡死鸡识别方法。在热红外图像配准技术上,分别提出两阶段与单阶段肉鸡死鸡识别方法。在两阶段识别方法中,使用实例分割算法获取彩色图像中肉鸡位置,提取单只肉鸡的热红外图像构建分类数据集,对肉鸡死鸡进行分类识别。单阶段识别方法中,将彩色图像与热红外图像进行融合,构建融合图像数据集,使用目标检测算法进行死鸡的识别。

1 材料与方法

1.1 数据采集

本研究的图像数据采集于山东民和牧业股份有限公司商品肉鸡养殖场,采集时间为 2023 年 11 月 7 日—12 月 14 日。该养殖舍采用叠层笼养的养殖方式,上下各 4 层,每笼长 2.4 m,宽 1.7 m,高1.3 m,每笼养殖肉鸡 60 ~ 70 只,笼具内部上方安装了一只白炽灯用于提供照明,笼内照度为 5 ~ 15 lx。图 1显示了现场图像采集装置示意图,组合相机固定在三角架上,使用便携式计算机通过 USB 数据线控制组合相机,从笼外倾斜向下约 40° 采集鸡群图像。组合相机包括一个英特尔 RealSense L515 型深度相机和艾睿光电 P2 型热红外相机,两个相机固定在相机固定件上,在保证深度相机和热红外相机镜头中心处于同一水平线且视野无相互遮挡的同时,尽可能调小两相机中心距,从而使两相机视野尽量重合。RealSense L515 型相机可以同时采集可见光图像、近红外图像与深度图像。深度相机使用飞行时间原理进行测距,运行功率为 3.5 W,视场角为 70° × 55°,分辨率为 1 024 像素 × 768 像素;彩色相机视场角为 70° × 43°,最大分辨率为 1 920 像素 × 1 080 像素,帧率均为 30 f/s。P2 型热红外相机的分辨率为 256 像素 × 192 像素,视场角为 56.0° × 42.2°,测温范围为 -20 ~ 170℃,误差为 ±2℃。



图 1 图像采集装置示意图

Fig. 1 Schematic of image acquisition device

使用自主开发的控制软件控制组合相机采集图像,在不影响养鸡场正常生产情况下,共采集 991 份鸡群图像,每份图像包括热红外图像、彩色图像、深度图像和近红外图像各 1 幅,用于构建肉鸡死鸡识

别数据集。

1.2　技术路线

根据信息提取方式不同分别提出了两阶段和单阶段肉鸡死鸡识别方法。如图 2 所示，在预处理部分，使用热红外相机与彩色相机的内参与外参将热红外图像与彩色图像进行配准，使热红外图像中的像素与彩色图像的像素一一对应。在两阶段肉鸡死鸡识别部分，由于彩色图像相比热红外图像有更多的颜色、纹理、形状信息，首先使用实例分割网络对彩色图像中的肉鸡（死鸡和活鸡）进行分割，根据分割得到的肉鸡掩膜得到肉鸡位置信息，从配准热红外图像中提取出个体肉鸡的热红外图像，构建出单只肉鸡的热红外图像数据集，使用图像分类网络对构建的单只肉鸡热红外图像数据进行分类；在单阶段的死鸡识别部分，通过将配准后的热红外图像与彩色图像进行融合，构建了热红外-彩色融合图像数据集，使用目标检测算法对图像中的肉鸡死鸡进行检测识别。

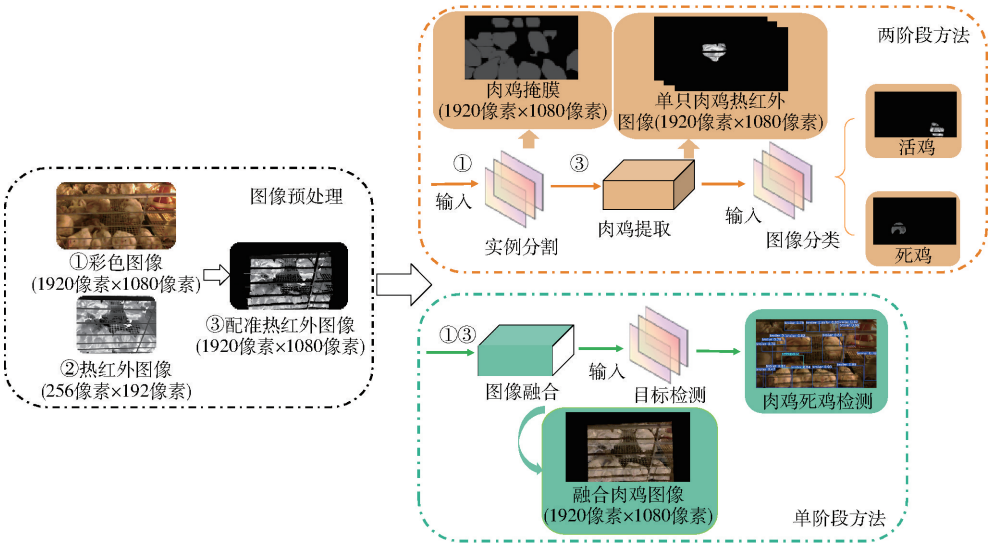

图 2　基于配准热红外图像的肉鸡死鸡识别流程图

Fig. 2　Registered thermal infrared image based dead broiler detection flowchart

1.3　图像预处理

为了能够更好地利用热红外图像中肉鸡个体温度信息，需要将鸡群中的热红外图像与彩色图像进行位置配准。由于采集的彩色图像分辨率高，热红外图像分辨率低，位置配准的目标为将热红外图像投影到彩色图像的坐标系中。图 3 为将热红外图像配准到彩色图像的流程示意图。首先使用热红外相机的内参矩阵 $\boldsymbol{K}^t_{3\times3}$ 将热红外图像中的像素点坐标 $P(u,v)$ 投影到热红外相机坐标系，得到点 P 在相机坐标系坐标 (u_t,v_t,z_t)，接着利用两个相机外参矩阵（包括旋转矩阵 $\boldsymbol{R}^t_{3\times3}$、$\boldsymbol{R}^c_{3\times3}$ 和平移矩阵 $\boldsymbol{T}^t_{1\times3}$、$\boldsymbol{T}^c_{1\times3}$）将点 P 由热红外相机坐标系中转换到彩色相机坐标系中 (x_c,y_c,z_c)，最后使用彩色相机的内参矩阵 $\boldsymbol{K}^c_{3\times3}$ 将点 P 投影到彩色图像的坐标系中，从而将热红外图像配准到彩色图像坐标系中，使两幅图像中像素一一对应。彩色图像与热红外图像配准的计算公式为

$$\begin{bmatrix}x\\y\\1\end{bmatrix}=K^c\left[(\boldsymbol{R}^c)^{-1}\left(z_t\boldsymbol{R}^t(\boldsymbol{K}^t)^{-1}\begin{bmatrix}u\\v\\1\end{bmatrix}+\boldsymbol{T}^t\right)-\boldsymbol{T}^c\right]\Big/z_c \tag{1}$$

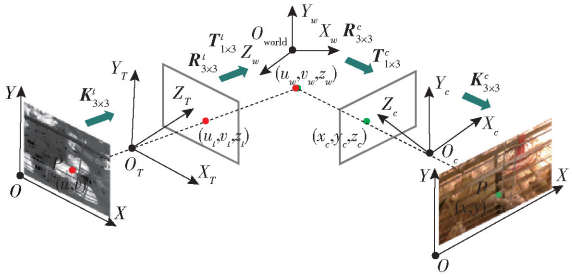

图 3　热红外图像配准流程示意图

Fig. 3　Schematic of image registration process

其中

$$z_t=z_c \tag{2}$$

图 4 为使用图像配准后的彩色图像与热红外图像示例。热红外图像中的像素值根据目标温度范围进行了归一化，像素值 255 表示最高温度，最小像素值 0 表示没有温度信息。配准后热红外图像中的黑色边界是由于彩色相机视野范围大于热红外相机的

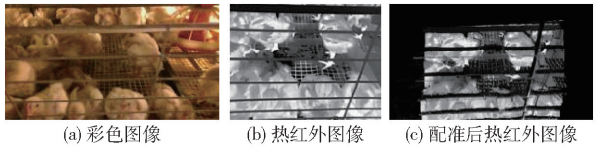

(a) 彩色图像　(b) 热红外图像　(c) 配准后热红外图像

图 4　彩色图像、热红外图像和配准后热红外图像

Fig. 4　RGB image, theraml infrared image and registered thermal infrared image

视野范围,导致热红外图像不包含周围黑色部分的信息,而图像内部水平方向黑色线条是由于鸡笼笼门金属丝边缘深度信息丢失导致热红外图像无法正确配准[16]。

1.4 两阶段热红外死鸡识别方法

1.4.1 肉鸡实例分割模型

实例分割的任务是对图像中的每个对象的像素级边界进行预测,在两阶段方法中,通过实例分割算法可以获取彩色图像中每只肉鸡掩膜像素,即获取配准热红外图像中肉鸡的像素位置。基于卷积神经网络的实例分割算法可以分为以 Mask R-CNN[17] 为代表的两阶段的实例分割算法和以 YOLACT[18]、SOLO v2[19] 为代表的单阶段实例分割算法。YOLO v11[20] 是 Ultralytics 团队提出最新的 YOLO 系列的算法,该算法能够支持目标检测任务,目标追踪、实例分割、姿态检测等任务。YOLO v11 网络在检测精度、检测速度和模型参数量上均取得了优异的表现。图 5 为 YOLO v11 网络结构示意图,YOLO v11 相比 YOLO v8 网络在主干网络中创新了 C3k2 模块和 C2PSA 模块,用于提高网络特征提取能力,在检测头部分进行了轻量化设计,降低模型参数量。YOLO v11-seg 网络是 YOLO v11 系列模型中用于实例分割任务的网络,在 YOLO v11 的检测分支添加了额外的分割分支,用于生成掩膜的原型图,并在检测分支并行地添加了生成每个预测框的掩膜系数的分支,通过将掩膜原型与掩膜系数线性组合操作生成实例分割的掩膜结果。由于 YOLO v11-seg 网络优秀的检测精度和检测速度,使用 YOLO v11-seg 网络对彩色图像中的所有肉鸡进行分割,并获取彩色图像中每只肉鸡的掩膜和坐标。

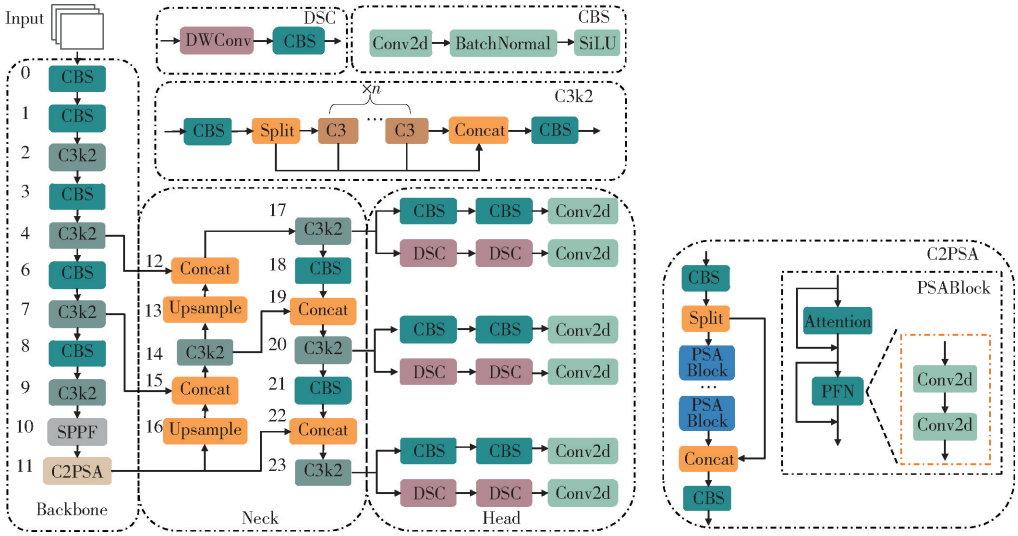

图 5 YOLO v11 网络结构示意图

Fig. 5 Schematic of YOLO v11 structure

1.4.2 基于单只肉鸡热红外图像的肉鸡死鸡分类

热红外图像在配准过程中,由于深度相机采集的深度图像质量较差,在热红外图像中出现了大量的噪声点,因此首先使用中值滤波的方法对配准后的热红外图像进行去噪处理。在获得肉鸡的掩膜图像后,遍历掩膜图像中每个掩膜的位置,并提取出每个肉鸡掩膜位置的单只肉鸡热红外图像,保存为与彩色图像相同尺寸。单只肉鸡热红外图像的提取流程如图 6 所示,由于热红外相机的视野范围小于彩色相机,配准热红外图像中包含部分没有温度信息的像素,在提取单只肉鸡红外图像时,需要将在不包含热红外信息像素范围的肉鸡掩膜去除。通过判断每个肉鸡掩膜的中心点 $M(i,j)$ 是否位于配准热红外图像中有效像素的最大内接矩形范围,来去除无效的肉鸡热红外图像。最后将提取的单只肉鸡热红外图像构建成新的单只肉鸡热红外图像数据集,使用图像分类网络来对构建的单只肉鸡热红外图像数据集进行分类。分类公式为

$$M(i,j)=\begin{cases}1 & (x_0\leqslant i\leqslant x_1;y_0\leqslant j\leqslant y_1)\\ 0 & (\text{其他})\end{cases} \tag{3}$$

式中 (i,j)——肉鸡掩膜中心点坐标

(x_0,y_0)——配准后热红外图像中有效像素的最大内接矩形左上角坐标

(x_1,y_1)——配准后热红外图像中有效像素的最大内接矩形右下角坐标

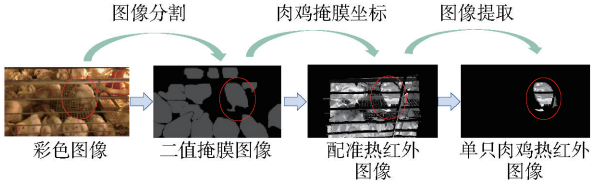

图 6 单只肉鸡热红外图像提取流程示意图

Fig. 6 Acquisition process single broiler thermal infrared image

1.5　单阶段肉鸡死鸡识别

目标检测算法能够在图像中标记感兴趣的目标的位置和类别，是实现自动化检测的理想方案。然而，由于叠层笼养肉鸡舍中光照环境限制，彩色图像的质量往往无法满足精准检测的需求。热红外图像中包含了每只肉鸡的温度信息，将热红外图像与彩色图像进行融合使卷积神经网络同时提取肉鸡的颜色、纹理、形状和温度特征是提高肉鸡死鸡检测精度的有效途径。彩色图像为三通道的 RGB 图像，而配准后的热红外图像为单通道的灰度图像，因此应当选择合适的融合方法构建融合图像用于肉鸡死鸡的识别。本研究分别选择 4 种彩色图像与热红外图像融合方案用于构建彩色-热红外融合图像数据集。方案 1：将热红外图像替换彩色图像的 G 通道，构建 G 通道替换融合图像；方案 2：将热红外图像分别与彩色图像三通道进行加权融合，构建加权融合图像；方案 3：对彩色图像和热红外图像分别使用小波变换后进行 1∶1加权融合，构建小波变换融合图像；方案 4：使用二维傅里叶变换将彩色图像与热红外图像转换到频域进行1∶1加权融合，构建频域变换融合图像。图 7 为 4 种彩色-热红外融合图像的示例。由于配准后热红外图像有效像素范围小于可见光图像，将所有融合图像以及可见光图像进行了填充处理使其保留相同面积的有效像素。最后，使用 YOLO v11 目标检测网络分别对彩色图像数据集和 4 种彩色-热红外融合图像数据集构建肉鸡死鸡检测模型。

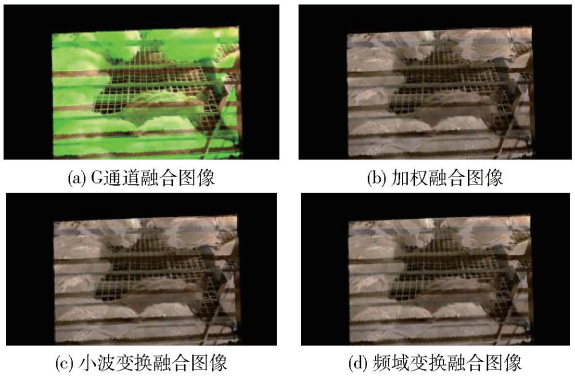

(a) G通道融合图像　(b) 加权融合图像

(c) 小波变换融合图像　(d) 频域变换融合图像

图 7　彩色图像与热红外图像融合图像示例

Fig. 7　Examples of fusion images of color images and thermal infrared images

1.6　实验平台

本研究所有的图像处理、数据集构建以及模型训练、验证工作均基于同一台台式计算机进行，该计算机配备 Intel(R) Core i9 - 11980HK@2.6 Hz 处理器，以及 NVIDIA GeForce RTX 3090 显卡，显存容量为 24 GB。所有数据处理与模型训练都在 Ubuntu 20.04 系统上运行，代码均使用 Python 编程语言编写，在 Pytorch 框架下运行。

1.7　数据集构建

为了对两阶段与单阶段肉鸡死鸡识别方法进行对比，随机选择了 100 份肉鸡图像构建了公共测试数据集。剔除部分低质量图像，将剩余 877 份图像用于构建实例分割与目标检测数据集。在肉鸡实例分割图像标注中，所有肉鸡(死亡肉鸡和正常肉鸡)均标注为“broiler”类别，按照 8∶2划分训练集和验证集。在肉鸡死鸡目标检测图像标注过程中，正常肉鸡标记类别为“broiler”，死亡肉鸡标记类别为“dead”，按照 8∶2划分为训练集和验证集。

2　结果与讨论

2.1　肉鸡实例分割结果

在两阶段的热红外肉鸡死鸡识别方法中，准确分割出彩色图像中的每个肉鸡个体是构建热红外肉鸡死鸡分类数据集的重要步骤。通过对比 YOLO v11s - seg、YOLO v11n - seg、YOLO v8s - seg、YOLO v8n - seg、YOLO v5s - seg、Mask R - CNN、YOLACT 和 SOLO v2 网络在验证集上的平均精确率(AP)、内存占用量和浮点计算量、推理速度(FPS)指标，选择最优的分割模型。不同肉鸡实例分割网络的性能对比结果如表 1 所示。基于 YOLO v11s - seg 构建的肉鸡实例分割模型取得了最高的分割平均精确率，为 94.5%，相比于 YOLO v8s - seg 和 YOLO v5s - seg 网络分别提高 0.5、0.7 个百分点，分别比 Mask R - CNN、YOLACT、SOLO v2 网络提高 6.5、5.5、6.1 个百分点。YOLO v11s - seg 网络作为最新 YOLO 系列的网络，模型主干网络不仅融合了 YOLO v8s - seg 和 YOLO v5s - seg 中的 C2f 模块和 C3 模块结构，更添加了自注意力机制模块 C2PSA 来增强网络对重要特征的提取能力，相比于 Mask R - CNN、YOLACT 和 SOLO v2 网络，使用的 ResNet 系列网络作为主干具有更强的特征提取与表达能力。内存占用量和浮点计算量分别描述模型空间与时间复杂度，所有模型中 YOLO v11n - seg 网络内存占用量和浮点计算量均为最小，分别为 2.7 MB、1.02×10^{10}，推理速度最快为 144.9 f/s。这表明 YOLO v11n - seg 网络在结构设计上相比其他网络更加精简高效。与 YOLO v11s - seg 网络相比，YOLO v11n - seg 网络深度和宽度更小，内存占用量和浮点计算量分别约为YOLO v11s- seg 的 1/3，推理速度更快，而模型平均精确率仅降低 0.3 个百分点。综合各个模型性能参数，YOLO v11n - seg 为最佳的肉鸡实例分割模型。

表 1 不同肉鸡分割模型性能对比

Tab. 1 Performance comparison of different segmentation models

分割模型	平均精确率/%	内存占用量/MB	浮点计算量	推理速度/(f·s^{-1})
YOLO v11s - seg	94.5	9.6	3.53×10^{10}	142.9
YOLO v11n - seg	94.2	2.7	1.02×10^{10}	144.9
YOLO v8s - seg	94.0	11.2	4.24×10^{10}	122.0
YOLO v8n - seg	93.5	3.1	1.20×10^{10}	128.2
YOLO v5s - seg	93.8	7.1	2.57×10^{10}	153.8
Mask R - CNN	88.0	43.9	1.11×10^{11}	46.2
YOLACT	87.0	34.7	6.14×10^{10}	48.0
SOLO v2	88.4	46.6	1.12×10^{11}	45.9

2.2 两阶段肉鸡死鸡分类识别结果

死亡肉鸡与正常肉鸡的热红外图像有着明显的差异。本研究使用图像分类的方法对提取的单只肉鸡热红外图像进行分类,并对使用 YOLO v11s - cls、YOLO v8s - cls、ResNet - 50、ResNet - 101、MobileNet v4[21]和 EfficientVIT[22]网络构建的单只肉鸡热红外图像分类模型进行了对比,从而选择最优分类模型。使用模型准确率、精确率、召回率和推理速度作为模型评价指标。人工对上一步实例分割得到的单只肉鸡热红外图像进行分类,共得到单只死亡肉鸡热红外图像 757 幅,正常肉鸡热红外图像 7 687 幅,共计 8 444 幅图像,按照比例 8∶2划分训练集和测试集,并使训练集和测试集均包含不同周龄的单只肉鸡热红外图像。

表 2 显示了使用不同的分类模型构建的单只肉鸡热红外图像在验证集上的表现。其中基于 YOLO v8s - cls 构建的肉鸡死鸡分类模型的分类精确率、准确率与推理速度均为最高,准确率为 99.4%,精确率为 95.4%,召回率为 96.9%,推理速度为 526.3 f/s。由于单只肉鸡热红外图像背景单一,特征提取任务相对简单,基于 YOLO v11s - cls、ResNet - 50、ResNet - 101、MobileNet v4 和 EfficientVIT 分类网络均取得了与 YOLO v8s - cls 相似的分类准确率,分别为 99.1%、99.2%、99.2%、98.2% 和 98.9%,其中 YOLO v11s - cls 分类网络推理速度相比最高,为 476.2 f/s,仅次于 YOLO v8s - cls 分类网络。

表 2 不同分类模型性能对比

Tab. 2 Comparison of classification performance of different models

分类模型	准确率/%	精确率/%	召回率/%	推理速度/(f·s^{-1})
YOLO v11s - cls	99.1	94.7	94.7	476.2
YOLO v8s - cls	99.4	95.4	96.9	526.3
ResNet - 50	99.2	93.2	97.6	172.4
ResNet - 101	99.2	93.9	96.9	106.4
MobileNet v4	98.2	85.7	92.6	434.8
EfficientVIT	98.9	93.2	93.2	227.3

2.3 单阶段肉鸡死鸡检测结果

为了对比不同融合图像数据集对肉鸡死鸡的识别效果,使用 YOLO v11s 目标检测网络构建基于彩色-热红外融合图像数据集的肉鸡死鸡检测模型,并使用模型在死鸡类别的平均精确率以及模型准确率、召回率、F1 分数作为评价指标。表 3 为使用不同图像数据集构建的肉鸡死鸡检测模型性能对比结果,基于小波变换融合图像构建的肉鸡死鸡检测模型检获得了最高的检测精度,模型平均精确率为 93.0%,准确率为 91.7%,模型召回率为 87.2%,F1 分数为 89.4%。模型平均精确率、准确率、F1 分数分别高于基于彩色图像构建的肉鸡死鸡检测模型 3.3、3.5、0.9 个百分点,召回率略有下降。基于 G 通道融合图像,加权融合图像与频域变换融合图像构建的肉鸡死鸡识别模型的检测精度依次降低,但均高于彩色图像数据集构建的模型。综上,使用彩色-热红外融合图像进行肉鸡死鸡检测能够获得比彩色图像更高的肉鸡死鸡检测精度,其中最佳的彩色-热红外图像融合方案为将热红外与彩色图像进行小波变换后加权融合构建的融合图像。

表 3 基于不同融合图像的肉鸡死鸡识别效果对比

Tab. 3 Comparison of detection performance of dead broiler based on different fusion images %

数据集	平均精确率	精确率	召回率	F1 分数
彩色图像	89.7	88.2	88.9	88.5
G 通道融合图像	92.0	89.8	87.8	88.8
加权平均融合图像	91.8	94.6	82.9	88.4
小波变换融合图像	93.0	91.7	87.2	89.4
频域变换融合图像	90.4	90.2	84.9	87.4

表 4 对比了 YOLO v11s、YOLO v11n、YOLO v8s、YOLO v8n 和 RT - DET - ResNet50[23]目标检测网络在小波变换融合数据集上的构建肉鸡死鸡检测模型的检测精度,YOLO v11s 相比于其他网络获检测精度最高,检测速度仅次于 YOLO v11n。在图 8 中分别将 5 个网络的瓶颈网络金字塔的每层输出特征图进行了热力图可视化,从图 8 可以看出 YOLO v11s 网络的高响应区域更好地集中分布在肉鸡(死鸡)身上,这表明 YOLO v11s 网络能够更好地从复杂背景中提取肉鸡区域的信息,从而实现肉鸡死鸡检测的效果。

2.4 两阶段与单阶段肉鸡死鸡识别方法对比

两阶段识别方法首先利用彩色图像中的肉鸡轮廓信息,获取单只肉鸡的热红外图像,使用卷积神经网络提取热红外图像中的温度特征对死亡肉鸡进行

表 4　不同检测网络肉鸡死鸡识别性能对比

Tab. 4　Comparison of performance of different networks in identifying dead broilers

模型	平均精确率/%	精确率/%	召回率/%	F1 分数/%	推理速度/(f·s^{-1})
YOLO v11s	93.0	91.7	87.2	89.4	163.9
YOLO v11n	89.8	85.9	87.2	86.5	175.4
YOLO v8s	91.7	87.3	87.3	87.3	133.3
YOLO v8n	88.3	87.9	82.7	85.2	149.3
RT－DET－ResNet50	88.5	87.8	82.4	85.0	42.4

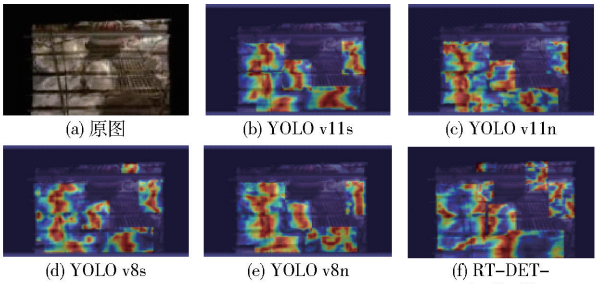

(a) 原图　(b) YOLO v11s　(c) YOLO v11n

(d) YOLO v8s　(e) YOLO v8n　(f) RT-DET-ResNet50

图 8　热力图

Fig. 8　Heat maps

分类。单阶段肉鸡死鸡识别方法，将彩色图像与配准热红外图像进行融合，基于卷积神经网络来同时提取融合图像中的颜色、纹理、轮廓和温度信息对死亡肉鸡进行检测。两阶段方法使用实例分割剔除了热红外图像中背景的干扰，在分类模型上获得了比单阶段目标检测方法更高的精度。然而两阶段肉鸡死鸡识别方法的识别效果同时受实例分割与分类的精度影响，通过分类精度与目标检测精度无法判断两种方法对肉鸡死鸡识别的性能差异。

为了进一步对比两种方法对肉鸡死鸡的检测效果，将两种方法分别在 100 幅公共测试图像进行了验证测试。测试结果如图 9 所示，单阶段方法死鸡识别精确率为 92.3%，两阶段方法死鸡识别精确率为 85.9%。其中，两阶段方法中 6 只肉鸡死鸡未被分割，5 只肉鸡被错分类，单阶段方法中，5 只肉鸡死鸡漏检，1 只死鸡被误检为正常肉鸡。未被分割与漏检的死亡肉鸡均处于被严重遮挡状态，而分类失败的死亡肉鸡均为高周龄肉鸡图像。图 9 中使用红色矩形框标记了图像中漏分割与漏检的死亡肉鸡，死亡肉鸡只有少部分面积暴露，神经网络难以提取充分的死亡肉鸡特征，造成了肉鸡分割与识别困难。

肉鸡死鸡识别的速度、模型内存占用量和模型部署难度等因素共同决定了方法的应用前景。在两阶段肉鸡死鸡方法中，单幅肉鸡图像检测耗时为实例分割耗时(6.9 ms)与图像中所有的单只肉鸡的热红外图像进行分类耗时($n \times 1.9$ ms，n 表示每幅肉鸡图像中提取的单只肉鸡热红外图像数量)的总和，而在单阶段识别算法中，对单幅图像的检测耗时为模型的推理时间(6.1 ms)。综上所述，基于热红外配准图像提出的单阶段肉鸡死鸡检测方法在公共测试集上获得了更高的识别精度，单阶段算法检测速度更快，模型部署更为简单，适合后期的部署与应用。

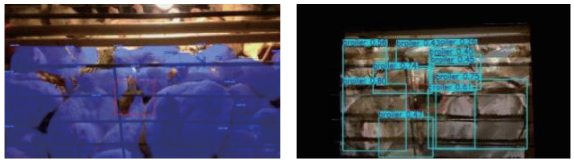

(a) 漏分割肉鸡死鸡　(b) 漏检测肉鸡死鸡

图 9　漏分割与漏检测肉鸡死鸡图像示例

Fig. 9　Examples of failed detection and segmentation images for dead broiler

2.5　2 周龄与 6 周龄肉鸡体表温度分布

肉鸡体表温度与热红外图像的像素值成正比。图 10 中分别统计了 105 幅 2 周龄死亡肉鸡图像、120 幅正常肉鸡图像、135 幅 6 周龄死亡肉鸡图像和 150 幅正常肉鸡图像中的像素值分布。如图 10a、10b 所示，2 周龄的死亡肉鸡像素值平均数与众数主要分布在 50～100 之间，而正常肉鸡像素值的平均数分布在 100～150 之间，众数分布在 150～200 之间，均高于死亡肉鸡。死亡肉鸡的体表温度分布相比更加集中，死亡肉鸡与正常肉鸡像素值的标准差分别分布在 0～50 之间和 50～100 之间。一些死亡肉鸡出现了像素最大值与正常肉鸡相同的异常，这是由于分割误差导致正常肉鸡像素被错误统计到了死亡肉鸡中。在图 10c、10d 中，6 周龄的死亡肉鸡与正常肉鸡像素值分布与 2 周龄肉鸡表现出了相同的分布差异，正常肉鸡像素值的平均值、众数、标准差均明显高于死亡肉鸡，并且死亡肉鸡像素整体分布低于 2 周龄肉鸡，其最大值分布在 100～255 之间，分布离散。

2.6　与其他死鸡识别方法进行对比

文献[16]基于图像配准技术将叠层笼养蛋鸡热红外图像、深度图像与近红外图像分别融合，构建融合图像数据集，使用目标检测算法对融合图像进行死鸡检测，结果表明在多源融合图像中，基于近红外–热红外融合图像构建的蛋鸡死鸡检测模型获得了最佳的检测精度，而在单源图像中，基于近红外图像数据集构建的蛋鸡死鸡检测模型取得了最佳的检测精度。为了对比本研究提出的单阶段肉鸡死鸡研究方法的有效性，分别构建了肉鸡热红外–近红外融合图像数据集和肉鸡近红外图像数据集来对肉鸡死鸡进行检测，与本文提出的单阶段目标检测方法进行对比。图 11 显示了使用不同融合图像构建的肉

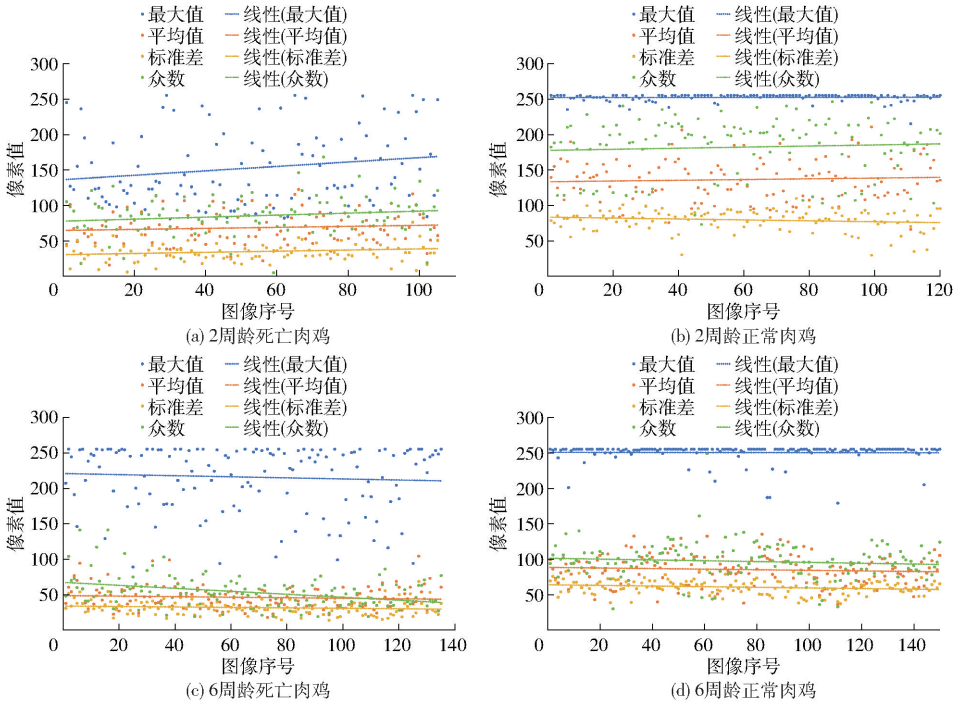

图 10 肉鸡热红外图像像素值分布

Fig. 10 Distributions of pixel values of broiler in thermal infrared images

鸡死鸡检测模型对肉鸡死鸡的识别精度。基于小波变换的彩色-热红外图像构建的肉鸡死鸡检测模型取得了最高的检测精度,相比近红外-热红外融合图像模型平均精确率、召回率、F1 分数分别提高 3.2、1.5、1.7 个百分点,而精确率仅下降 0.3 个百分点。使用彩色图像数据集构建的肉鸡死鸡检测模型也同样取得了比仅使用近红外图像和配准热红外图像模型更高的检测精度,模型平均精确率分别提高 3.8、7.1 个百分点,模型 F1 分数分别提高 9.1、7.1 个百分点。这表明使用彩色与热红外图像进行融合能够取得比近红外与热红外图像融合更高的肉鸡死鸡识别精度。

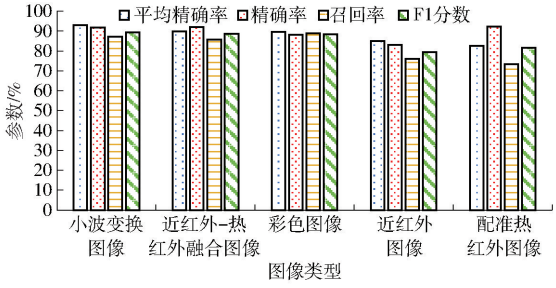

图 11 基于不同图像构建的肉鸡死鸡识别模型性能对比

Fig. 11 Performance comparison of dead broiler detection models built based on different images

与两阶段方法相似,文献[24]使用热红外与彩色相机对固定区域与数量的肉鸡采集图像,使用背景差减法分割出热红外图像与可见光图像中的肉鸡个体,根据可见光与热红外图像中肉鸡数量的差异,实现对肉鸡死鸡的识别。为了适应叠层笼养肉鸡舍中不同笼位的复杂光照条件,本研究使用实例分割方法替代背景差减法对彩色图像中的肉鸡个体进行分割,以更好地适应高密度养殖环境,由于热红外图像分辨率低,信息少,分割困难,使用彩色图像的分割结果获取热红外图像中的肉鸡位置,对单只肉鸡进行分类能够更好地利用热红外图像中的信息,实现对肉鸡死鸡的识别。

相比于文献[25]通过固定在蛋鸡腿部的脚环来记录蛋鸡的活动状态对蛋鸡死鸡识别的研究,本研究中提出的两种基于图像的肉鸡死鸡识别方法,具有低入侵、更高效的优点,能够快速实现对肉鸡群体中的死鸡进行识别,更加具有应用前景。

2.7 讨论

两阶段肉鸡死鸡识别方法的精度受实例分割算法影响最大,实例分割模型无法分割出彩色图像中的肉鸡死鸡,导致无法提取单只肉鸡死鸡热红外图像,进而无法实现有效分类。单阶段肉鸡死鸡识别方法精度受遮挡目标影响较大,肉鸡死鸡暴露面积较小,特征较少,容易漏检和误检。

小目标和遮挡目标的检测与识别是目标检测和实例分割网络发展中的重要问题。造成两阶段与单阶段方法识别肉鸡死鸡识别失败的主要因素是对肉鸡死鸡的遮挡。在公共测试集中,对彩色图像中肉鸡的分割结果与目标检测结果表明,大部分被漏分割与检测的死亡肉鸡都处于被其他肉鸡严重遮挡的状态,具备小目标和遮挡特征。此外,图像质量低也是导致两种方法在公共测试集中检测精度不理想的

原因。实例分割需要识别肉鸡的纹理与边缘特征来在不同的肉鸡的像素之间进行准确分割，然而在低照度下采集的彩色图像存在细节模糊与遮挡难以区分的缺陷，致使肉鸡个体标注困难，分割效果不理想。配准后的热红外图像存在黑色外边框与内部黑色线条的缺陷也对精度有一定的影响，黑色外边框导致了彩色图像外围部分肉鸡信息的丢失，使单阶段与两阶段方法都无法充分利用到彩色图像中的信息；而内部黑色线条信息缺失部分，致使处于图像中黑色线条部分的肉鸡的热红外信息不完整，使单只肉鸡热红外图像与融合肉鸡图像中的肉鸡样本特征更加复杂，增加了肉鸡死鸡分类与识别难度。

3　结论

（1）两阶段肉鸡死鸡识别方法中，以彩色图像中肉鸡为分割对象，使用 YOLO v11n－seg 网络构建肉鸡分割模型，模型分割平均精确率为 94.2%。基于 YOLO v8－cls 网络构建肉鸡死鸡分类模型，模型分类准确率为 99.4%，精确率为 95.4%，召回率为 96.9%。

（2）在单阶段肉鸡死鸡识别方法构建的彩色–热红外融合图像数据集中，使用 YOLO v11 网络构建的肉鸡死鸡检测模型，在小波变换的彩色–热红外融合图像数据集上获得了最高的识别精度，死鸡类别平均识别精确率为 93.0%，精确率为 91.7%，召回率为 87.2%，F1 分数为 89.4%。

（3）对 2 周龄和 6 周龄的单只肉鸡热红外图像分析表明，死亡肉鸡和正常肉鸡的体表温度分布存在明显差异。与其他研究对比表明，本文提出的彩色–热红外图像融合肉鸡死鸡识别方法能够取得比使用彩色图像、热红外图像以及近红外–热红外融合图像更好的肉鸡死鸡识别效果。

（4）单阶段检测方法在公共测试集上取得了更高的检测精度（92.3%），推理速度更快（6.1 ms/f），部署容易，适合未来的算法部署与应用。

参　考　文　献

[1] 中国畜牧兽医网.《突围——中国白羽肉鸡自主育种记》[N/OL].（2022－01－06）. https://www.nahs.org.cn/dt/xwlb/202201/t20220106_395345.html.

[2] HAO H, FANG P, DUAN E, et al. A dead broiler inspection system for large-scale breeding farms based on deep learning[J]. Agriculture, 2022, 12(8): 1176.

[3] NASIRI A, AMIRIVOJDAN A, ZHAO Y, et al. An automated video action recognition-based system for drinking time estimation of individual broilers[J]. Smart Agricultural Technology, 2024, 7: 100409.

[4] LIU H W, CHEN C H, TSAI Y C, et al. Identifying images of dead chickens with a chicken removal system integrated with a deep learning algorithm[J]. Sensors, 2021, 21(11): 3579.

[5] LI Q, SI Y, CHU M, et al. A novel lameness detection method for dairy cows based on temporal gait and spatial post features [J]. Computers and Electronics in Agriculture, 2024, 224: 109172.

[6] 夏元天,寇旭鹏,薛洪成,等. 基于改进的 YOLO 检测框架的笼养白羽肉鸡行为检测算法[J]. 农业机械学报,2024,55(11):103－111.
XIA Yuantian, KOU Xupeng, XUE Hongcheng, et al. Behavior detection algorithm for caged white-feather broilers based on improved YOLO detection framework[J]. Transactions of the Chinese Society for Agricultural Machinery,2024,55(11):103－111.(in Chinese)

[7] 陈佳,丁奇安,刘龙申,等. 基于 YOLO v5 与短时跟踪的鸡只呼吸道疾病早期检测[J]. 农业机械学报,2023,54(1):271－279.
CHEN Jia, DING Qi'an, LIU Longshen, et al. Early detection of broilers respiratory diseases based on YOLO v5 and short time tracking[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(1):271－279.(in Chinese)

[8] 温毓晨,赵永杰,蒲六如,等. 基于改进 YOLO v5s 模型的奶山羊乳房区域热红外图像检测方法[J]. 农业机械学报,2024,55(6): 237－245.
WEN Yuchen, ZHAO Yongjie, PU Liuru, et al. Thermal infrared image detection method of dairy goat breast region based on improved YOLO v5s model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(6): 237－245.(in Chinese)

[9] 郭艳娇,杨圣慧,迟宇,等. 基于热红外图像的奶牛乳区温度分布与乳房炎识别方法[J]. 农业工程学报,2022,38(2):250－259.
GUO Yanjiao, YANG Shenghui, CHI Yu, et al. Recognizing mastitis using temperature distribution from thermal infrared images in cow udder regions[J]. Transactions of the CSAE, 2022,38(2):250－259.(in Chinese)

[10] 张旭东,康熙,马丽,等. 基于热红外图像的奶牛乳房炎自动检测方法[J]. 农业机械学报,2019,50(增刊):248－255,282.
ZHANG Xudong, KANG Xi, MA Li, et al. Automatic detection method of dairy cow mastitis based on thermal infrared image [J]. Transactions of the Chinese Society for Agricultural Machinery,2019,50(Supp.):248－255,282.(in Chinese)

[11] HARRIS-BRIDGE G, YOUNG L, HANDEL I, et al. The use of infrared thermography for detecting digital dermatitis in dairy cattle: what is the best measure of temperature and foot location to use? [J]. The Veterinary Journal, 2018, 237: 26－33.

（下转第 64 页）

[24] TAKANOBU R, ZHANG T, LIU J, et al. A hierarchical framework for relation extraction with reinforcement learning[C]// Proceedings of the AAAI Conference on Artificial Intelligence (AAAI), 2019: 7072 - 7079.
[25] JIANG M, SHANG J, CASSIDY T, et al. Metapad: meta pattern discovery from massive text corpora[C]// Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (SIGKDD), 2017: 877 - 886.
[26] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph attention networks[C]// International Conference on Learning Representations (ICLR), 2018.
[27] YANG B, YIH W T, HE X, et al. Embedding entities and relations for learning and inference in knowledge bases[C]// ICLR (Poster), 2015.
[28] YANG H W, ZOU Y, SHI P, et al. Aligning cross-lingual entities with multi-aspect information[C]// EMNLP/IJCNLP, 2019: 4430 - 4440.
[29] MIKOLOV T, CHEN K, CORRADO G, et al. Efficient estimation of word representations in vector space[C]// ICLR (Workshop Poster), 2013.
[30] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// IEEE Computer Society (CVPR), 2016: 770 - 778.
[31] XIAO S, ZHU D, TANG C, et al. Combining graph contrastive embedding and multi-head cross-attention transfer for cross-domain recommendation[J]. Data Science and Engineering, 2023, 8(3): 247 - 262.
[32] CHEN L, LI Z, XU T, et al. Multi-modal siamese network for entity alignment[C]// Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining (SIGKDD), 2022: 118 - 126.
[33] CHEN Z, CHEN J, ZHANG W, et al. MEAformer: multi-modal entity alignment transformer for meta modality hybrid[C]// ACM Multimedia (ACM), 2023: 3317 - 3327.

(上接第 55 页)

[12] MACHADO N A F, DA COSTA L B S, BARBOSA-FILHO J A D, et al. Using infrared thermography to detect subclinical mastitis in dairy cows in compost barn systems[J]. Journal of Thermal Biology, 2021, 97: 102881.
[13] 许志强, 沈明霞, 刘龙申, 等. 基于红外热图像的肉鸡腿部异常检测方法[J]. 南京农业大学学报, 2021, 44(2): 384 - 393.
XU Zhiqiang, SHEN Mingxia, LIU Longshen, et al. Abnormal recognition method of broiler leg based on infrared thermal image[J]. Journal of Nanjing Agricultural University, 2021, 44(2): 384 - 393. (in Chinese)
[14] DA FONSECA F N, ABE J M, DE ALENCAR NÄÄS I, et al. Automatic prediction of stress in piglets (*Sus scrofa*) using infrared skin temperature[J]. Computers and Electronics in Agriculture, 2020, 168: 105148.
[15] 贾雁琳, 薛皓, 周子轩, 等. 基于红外热成像技术的笼内死鸡自动识别方法[J]. 河北农业大学学报, 2023, 46(3): 105 - 112.
JIA Yanlin, XUE Hao, ZHOU Zixuan, et al. Automatic detection method for dead chicken in cage based on infrared thermal imaging technology[J]. Journal of Hebei Agricultural University, 2023, 46(3): 105 - 112. (in Chinese)
[16] LUO S, MA Y, JIANG F, et al. Dead laying hens detection using TIR - NIR - Depth images and deep learning on a commercial farm[J]. Animals, 2023, 13(11): 1861.
[17] HE K, GKIOXARI G, DOLLÁR P, et al. Mask R - CNN[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 36(9): 1137 - 1149.
[18] BOLYA D, ZHOU C, XIAO F, et al. YOLACT: real-time instance segmentation[C]// IEEE/CVF International Conference on Computer Vision (ICCV), 2019: 9156 - 9165.
[19] WANG X, ZHANG R, KONG T, et al. SOLOv2: dynamic and fast instance segmentation[J]. arXiv e-prints: 2003.10152, 2020.
[20] JJOCHER G, NISHIMURA K, MINEEVA T, et al. YOLOv11[EB/OL]. (2024 - 10 - 11)[2024 - 09 - 30]. https://github.com/ultralytics/ultralytics.
[21] QIN D, LEICHNER C, DELAKIS M, et al. MobileNetV4—universal models for the mobile ecosystem[J]. arXiv: 2404.10518, 2024.
[22] CAI H, LI J, HU M, et al. EfficientViT: multi-scale linear attention for high-resolution dense prediction[C]// IEEE/CVF International Conference on Computer Vision (ICCV), 2023: 17256 - 17267.
[23] ZHAO Y, LV W, XU S, et al. DETRs beat YOLOs on real-time object detection[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 16965 - 16974.
[24] MUVVA V V R M K R, ZHAO Y, PARAJULI P, et al. Automatic detection of broiler mortality using image processing technology[C]// 10th International Livestock Environment Symposium (ILES X). American Society of Agricultural and Biological Engineers, 2018.
[25] BAO Y, LU H, ZHAO Q, et al. Detection system of dead and sick chickens in large scale farms based on artificial intelligence [J]. Mathematical Biosciences and Engineering, 2021, 18(5): 6117 - 6135.