doi:10.6041/j.issn.1000-1298.2025.01.006

基于“图像-文本”间关联增强的多模态猪病知识图谱融合方法

蒋婷婷[1,2]　徐　澳[1,2]　吴飞飞[1,2]　杨　帅[1,2]　何　进[1,2]　辜丽川[1,2]

(1. 安徽农业大学信息与人工智能学院, 合肥 230036;
2. 智慧农业技术与装备安徽省重点实验室, 合肥 230036)

摘要: 传统的猪病防治主要依赖于人工经验,很可能因为人工疏忽存在疾病漏诊。为此,构建一个多模态猪病知识图谱,帮助管理者更好地理解猪只间的关联关系,为后续有效识别潜在的疾病传播路径和异常情况提供良好的数据基础。首先,从不同来源获取猪病数据,经过知识抽取以及图像匹配后初步构建两个多模态猪病知识图谱;其次,提出基于“图像-文本”间关联增强的多模态融合方法,利用多头注意力机制学习图像与文本之间的语义关联,通过减少猪病视觉模态模糊问题带来的负面作用,以增强猪病实体的向量表征;最后,基于对实体向量表征相似度的计算,融合两个多模态数据集中的猪病实体,以形成一个知识完备性更高的猪病知识图谱。实验表明,本文提出的多模态融合方法在猪病实体对齐任务上取得了优异的性能,相较于现有方法,对齐准确性(Hits@1)提升 0.033,在通用数据集 DBP_{ZH-EN}、DBP_{FR-EN}、DBP_{JA-EN}上进行实验验证,对齐准确性分别提升 0.152、0.236、0.180,证明了该方法在多模态知识图谱融合方面的有效性。

关键词: 猪病; 多模态知识图谱; 多模态融合; 实体对齐

中图分类号: TP391　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)01-0056-09　　**OSID**:

“Image - Text” Association Enhanced Multi-modal Swine Disease Knowledge Graph Fusion

JIANG Tingting[1,2]　XU Ao[1,2]　WU Feifei[1,2]　YANG Shuai[1,2]　HE Jin[1,2]　GU Lichuan[1,2]

(1. *School of Information and Artificial Intelligence*, *Anhui Agricultural University*, *Hefei* 230036, *China*
2. *Anhui Province Key Laboratory of Smart Agricultural Technology and Equipment*, *Hefei* 230036, *China*)

Abstract: Traditional swine disease prevention primarily relies on human expertise, which risks missed diagnoses due to human error. To address this challenge, a multi-modal swine disease knowledge graph was developed to assist managers in better understanding the connections between pigs, providing a solid data foundation for identifying potential disease transmission paths and anomalies. Firstly, the swine disease data from various sources were collected, and then two preliminary multi-modal knowledge graphs were constructed through knowledge extraction and image matching. Secondly, a multi-modal knowledge graph fusion method based on “image - text” association was proposed, using a multi-head attention mechanism to reduce the impact of visual ambiguity and enhance swine disease entity representation. Finally, by calculating the similarity of entity representations in vector space, entities from the two multi-modal datasets were integrated into a more comprehensive knowledge graph. Experiments demonstrated that the proposed method improved alignment accuracy, as reflected by a 0.033 increase in Hits@1 compared with that of existing methods. Additional accuracy gains of 0.152, 0.236 and 0.180 were observed on the DBP_{ZH-EN}, DBP_{FR-EN}, and DBP_{JA-EN} datasets respectively, demonstrating its effectiveness in multi-modal knowledge graph fusion.

Key words: swine disease; multi-modal knowledge graph; multi-modal fusion; entity alignment

收稿日期: 2024-11-01　修回日期: 2024-11-28

基金项目: 国家自然科学基金面上项目(32472007)和安徽省高等学校科学研究项目(自然科学类)重点项目(2023AH051020)

作者简介: 蒋婷婷(1995—),女,讲师,博士,主要从事知识图谱研究,E-mail: jiangtt@ahau.edu.cn

通信作者: 辜丽川(1974—),男,教授,博士,主要从事大数据和知识图谱研究,E-mail: glc@ahau.edu.cn

0　引言

生猪养殖作为我国重要产业，对于促进农业和经济发展具有重要意义[1-2]。然而，由于饲养规模大、密度高等，猪病时有发生，严重影响了我国生猪养殖的整体效益。传统的猪病防治主要依赖于人工经验，很可能因为人工疏忽存在疾病漏诊。随着人工智能技术的迅速发展，将知识智能服务应用于指导农业生产[3]和辅助农业决策已取得显著成效[4-5]。在猪病领域，2018 年挺好集团开发了一款智能养殖软件，基于 AI + AR 识别技术能够对猪病做出初步诊断；2022 年勃林格殷格翰中国公司推出的 AI 猪病识图小程序能够通过拍照自动识别猪的脏器大体病变，分析可能病因，并给出干预建议。这些研究推动了猪病领域的智能化，但其较为关注对猪病图像的处理，而猪病信息的描述形式多种多样，深入挖掘文本信息、结构信息对于猪病分析具有重要价值。

知识图谱[6]作为一种高效的知识管理工具，以结构化的方式存储知识，能够提供丰富的语义信息和支持复杂关系分析[7-8]。构建猪病知识图谱可以帮助管理者更好地理解猪只间的关联关系，分析猪只的健康数据，对于提升猪病诊断软件的可靠性具有很大潜力。由于猪病数据来源多样，涉及人工记录、专业文献[9]、传感器[10-11]收集等，收集整合多源异构的猪病数据形成高质量的知识图谱并不容易。尽管知识图谱技术已在医疗、金融等行业落地[12-14]，但猪病知识图谱的研究仍处于起步阶段[15]。

实体对齐作为知识图谱融合的关键步骤，能够有效促进知识完整性的提升和知识共享[16]。面向多模态知识图谱的实体对齐方法中，融入视觉信息对于对齐准确性的提升存在益处[17-20]。然而，在多模态知识图谱中并不能保证图像信息完全覆盖到每 1 个实体，即使公开数据集 DBP15K，其图像覆盖率依旧没有达到 100%[19]。为此，CHEN 等[21]设计循环缺失想象模块，通过为不存在图像的实体生成伪视觉嵌入，为解决图像缺失问题提供了解决方案。除此之外，视觉模态模糊问题也是有碍多模态实体对齐方法性能提升的另一影响因素，图像中描绘的背景特征或与实体关联较弱的特征可能会影响实体表征的准确性。尽管 CHEN 等[21]开始关注到该问题，但其没有深入考虑实体文本描述与图像之间的关联。而文本信息能够提供关于实体细粒度的描述，通过学习图像与文本之间的语义关联，能够帮助定位图像中更能表示实体的关键特征，从而减少视觉模态模糊问题带来的负面作用。

基于此，本文提出一种基于“图像-文本”间关联增强的多模态猪病知识图谱融合方法，旨在构建一个高质量的猪病知识图谱，为下游应用提供良好的数据基础。首先，从 2 个异构数据源出发构建 2 个多模态猪病知识图谱；其次，提出基于“图像-文本”间关联增强的多模态融合方法，关注图像信息的重要部分和避免视觉模态模糊问题[21]，以增强猪病实体的向量表征，通过向量的相似度判断实体对齐，进而融合两个多模态数据集中的猪病实体，以形成一个知识完备性更高的多模态猪病知识图谱。

1　多模态猪病知识图谱构建

1.1　总体构建流程

多模态猪病知识图谱构建的主要过程如图 1 所示，首先，采用数据预处理、信息抽取技术初步构建单模态知识图谱；其次，结合猪病名称检索猪病实体相关的图像，构建多模态知识图谱；最后，通过基于“图像-文本”间关联增强的多模态融合的实体对齐方法，对上述 2 个多模态知识图谱进行融合，得到最终的猪病知识图谱。

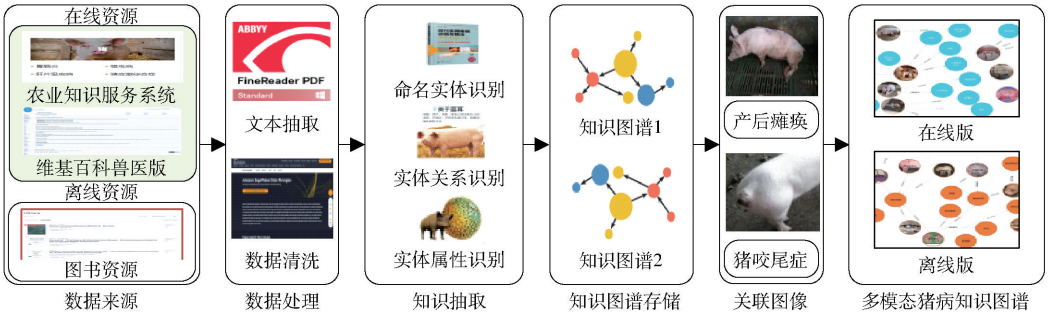

图 1　多模态猪病知识图谱构建流程图

Fig. 1　Process of building multi-modal knowledge graph of swine disease

1.2　数据来源

在构建猪病知识图谱时的文本数据包括两种来源，分别为在线资源、离线资源。其中在线资源包括从农业专业知识服务系统畜禽疾病百科的猪病板块（https://agri.nais.net.cn/insectpests/livestockency.html?type=%E7%8C%AA）以及中文维基百科

(https://zh.wikipedia.org/)中检索到的在线数据,离线资源包括图书资源的扫描文件以及电子文件格式的出版物。以在线资源与离线资源为基础,分别构建多模态猪病知识图谱。

1.3 单模态猪病知识图谱构建方法

单模态猪病知识图谱构建的目标是从碎片化、无规则的数据中抽取出实体、关系和属性,以三元组的形式构建知识图谱,主要包括数据预处理、知识抽取以及知识图谱存储 3 个步骤,具体为:

(1)数据预处理:对猪病相关文本进行标准化处理,提高数据质量。首先使用 Python 爬虫工具爬取在线文本数据,使用 FineReader PDF 获取离线文本数据;然后通过数据清洗工具 Amazon Sage Maker Data Wrangler 进行数据清洗操作,包括删除和纠正错误信息,更正数据格式;最后将文本数据分割成词语,并进行词性标注,为知识抽取做准备。

(2)知识抽取:从猪病数据中抽取有价值的信息转化为结构化数据,便于知识的存储和使用。首先,基于猪病领域知识构建包含猪病名称、类别等实体以及实体间层次结构和关联关系的猪病本体模型。然后,针对预处理完成的数据,利用本体模型来指导猪病相关特征词的抽取和识别。具体抽取方法为利用命名实体识别技术[22-23]、关系抽取[24]与属性抽取[25]从特征词中识别出关键实体名称、关系与属性,将识别的实体和关系转化为关系三元组〈头实体,关系,尾实体〉以及属性三元组〈实体,属性,属性值〉,其中关系三元组表示知识图谱的结构,属性三元组独立地与实体关联。抽取后的实体、关系、属性的描述如表 1 所示。其中,实体类别中包括各种猪病、疾病科别、发病部位、临床症状等具体描述;关系包括“别名”、“临床症状”、“疾病科别”、“猪病分类”、“畜禽类型”等具体关系,对于无法定义的模糊关系,采用“关键词”进行补充;属性包括“治疗药品”、“治疗方式”、“给药剂量”、“疾病病原”、“疾病描述”等属性,属性值为属性的具体描述,如属性三元组〈猪消化不良,给药剂量,人工胃液 10 至 20 毫升〉中对于实体“猪消化不良”的属性“给药剂量”的属性值为“人工胃液 10 至 20 毫升”。

(3)知识图谱存储:采用 Neo4j 数据库作为知识图谱存储与可视化工具,将步骤(2)构建的猪病关系三元组数据导入到数据库存储。

构建的单模态猪病知识图谱如图 2 所示,图 2a、2b 分别为使用在线资源构建的猪病知识图谱、使用离线资源构建的猪病知识图谱。

表 1 知识抽取内容描述

Tab.1 Types of knowledge extraction and corresponding descriptions

抽取对象	类型描述	内容描述
实体	猪病	“猪屎豆中毒”、“猪炭疽病”等
	疾病科别	“产科”、“消化科”等
	发病部位	“肠系膜淋巴结”、“气管粘膜”等
	临床症状	“拉稀”、“高热”等
关系	关系类型	“别名”、“临床症状”、“疾病科别”等
属性	属性	“治疗药品”、“治疗方式”、“给药剂量”等
	属性值	“人工胃液 10 至 20 毫升”、“静脉注射”等

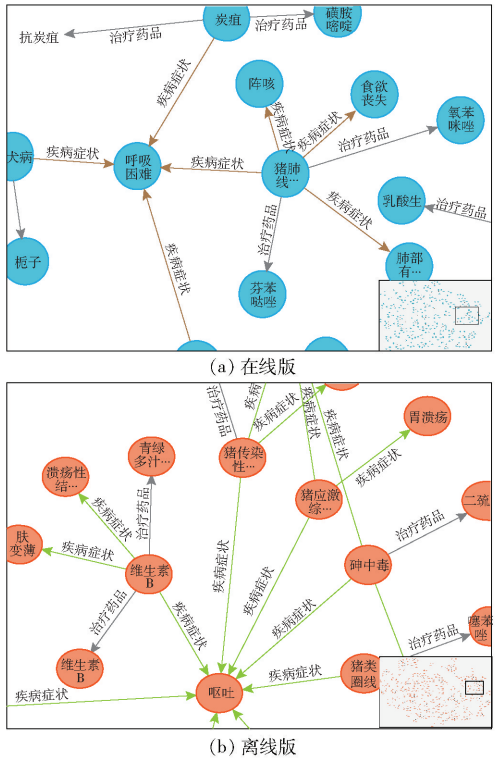

(a)在线版

(b)离线版

图 2 单模态猪病知识图谱

Fig. 2 Unimodal swine disease knowledge graphs

1.4 多模态猪病知识图谱构建方法

多模态猪病知识图谱构建目的为猪病实体关联图像信息,图像来源包括人工采集与维基百科。对于单模态知识图谱中的每 1 个猪病实体,领域专家为图像进行筛选和标注,并以猪病实体名称命名图像,构建完成的多模态猪病知识图谱如图 3 所示,本文将所构建的多模态猪病知识图谱命名为 Multi-odal Knowledge Graph of Swine Disease(以下简称 SDMKG)。

2 多模态猪病知识图谱融合

2.1 总体框架

本文提出的基于“图像-文本”间关联增强的多模态猪病知识图谱融合方法(以下简称 ITEA)整体框架如图 4 所示,该模型主要包括 3 个部分:基础编码器、“图像-文本”间关联增强的多模态融合模块和实体对齐模块。

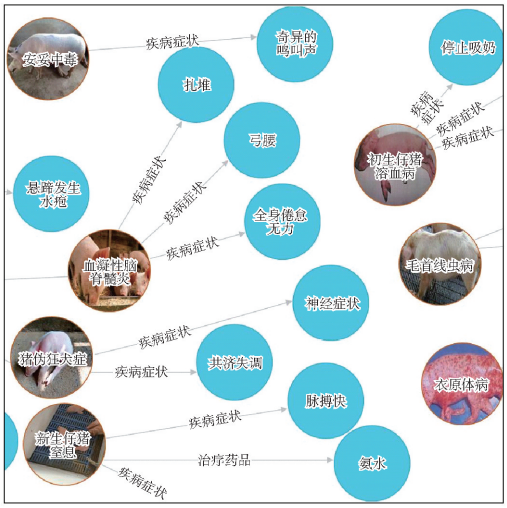

(a) 在线版局部展示

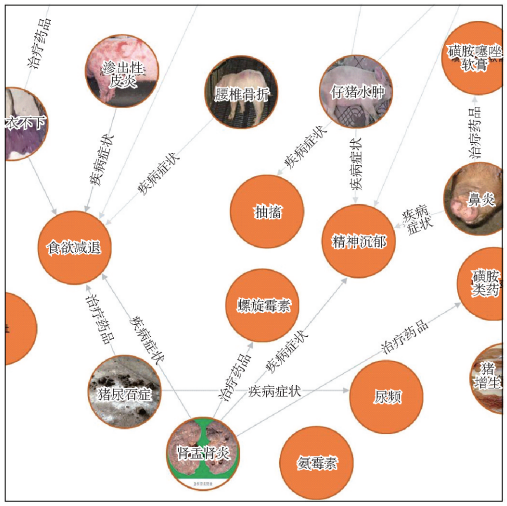

(b) 离线版局部展示

图 3　多模态猪病知识图谱

Fig. 3　Multi-modal swine disease knowledge graphs

2.2　基础编码器

基础编码器包括结构编码器、文本编码器以及图像编码器。结构编码器捕获知识图谱的结构信息，并编码成低维向量，方便机器理解。具体采用具有两个注意力头的图注意网络（Graph attention network，GAT）[26]捕获知识图谱的结构信息，并采用对角权重矩阵[27]进行线性变换，最终的图嵌入 $\boldsymbol{H}_G$ 为

$$\boldsymbol{H}_G = GAT(\boldsymbol{W}_G, \boldsymbol{M}_G; \boldsymbol{x}_i^G) \quad (\boldsymbol{W}_G \in \mathbf{R}^{d\times d}) \quad (1)$$

式中　$\boldsymbol{W}_G$——对角线权重矩阵

$\boldsymbol{M}_G$——图邻接矩阵

$\boldsymbol{x}_i^G$——图谱中第 i 个实体的随机初始化向量

d——嵌入维度

文本编码器采用词袋模型[28]，以文本三元组为语料，训练猪病文本信息的嵌入，确保每个猪病实体都能被编码，避免超出词汇表（Out of vocabulary，OOV）问题[29]。图像编码器是为学习图像中的重要特征，采用预训练的 ResNet152[30]模型。

2.3　“图像-文本”间关联增强的多模态融合

视觉模态模糊问题是指实体的图像信息无法精确地表达实体[21]，这种问题通常会导致机器难以识别图像中的重要特征。如图 5 所示，左图为猪瘟，右图为猪眼结膜炎。两者在病症上均包含眼结膜发红现象，在一般的图像学习中，眼结膜发红会被当作关键特征，从而导致猪眼结膜炎和猪瘟被视为同一病症。本文认为，此问题的关键在于图像中缺少与实体描述关联强的特征，例如，从猪眼结膜炎的文本描述中可以挖掘到该病症关键信息还包含流出多量浆液以及角膜混浊，从文本中可以区分二者。因此，本文提出“图像-文本”间关联增强的多模态知识图谱融合方法，通过增强图像与文本中关键信息的关联，从而提高多模态知识图谱的融合效果。

多头交叉注意力机制通常被用来捕捉跨域信息之间的关联，通过跨域共享促进知识学习[31]。在多模态信息融合中，多头交叉注意力机制同样可以对不同模态信息之间的关系进行建模，从而增强跨模态信息之间的关联。首先，使用实体的图像嵌入 $\boldsymbol{H}_I$ 以及文本嵌入 $\boldsymbol{H}_T$ 作为图像-语义关联增强模块的输入，并通过线性转换将图像嵌入转

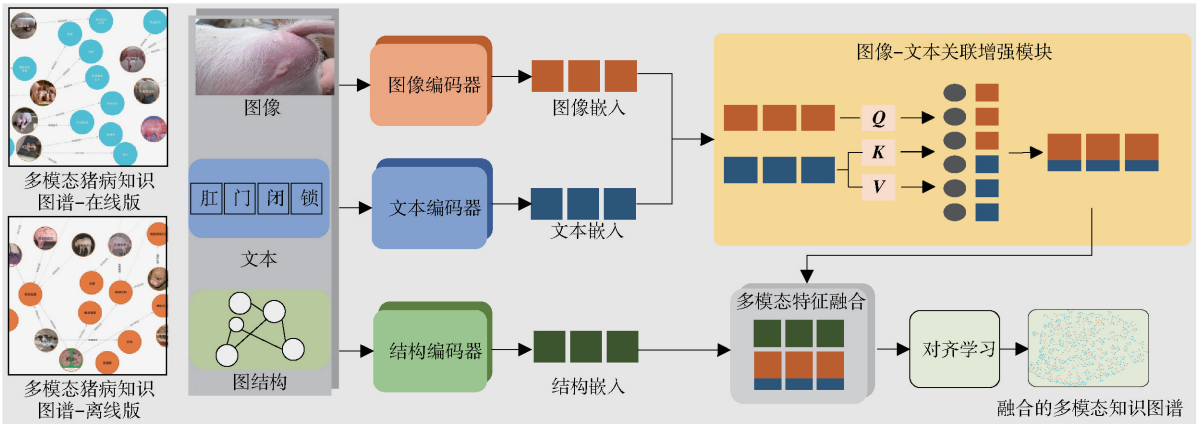

图 4　基于“图像-文本”关联增强的多模态知识图谱融合模型框架图

Fig. 4　Overall framework of multi-modal knowledge graph fusion method



眼结膜发红、呈胸式呼吸、弓背缩腹 (a) 猪瘟　　眼结膜红肿、流出多量浆液、角膜混浊 (b) 猪眼结膜炎

图 5　猪瘟与猪眼结膜炎对比

Fig. 5　Comparisons of swine fever and porcine conjunctivitis

换为查询向量 $\boldsymbol{Q}$,将文本嵌入转化为键向量 $\boldsymbol{K}$ 和值向量 $\boldsymbol{V}$,即

$$\boldsymbol{Q}=\boldsymbol{H}_I\boldsymbol{W}_Q \tag{2}$$

$$\boldsymbol{K}=\boldsymbol{H}_T\boldsymbol{W}_K \tag{3}$$

$$\boldsymbol{V}=\boldsymbol{H}_T\boldsymbol{W}_V \tag{4}$$

其中,$\boldsymbol{W}_Q$、$\boldsymbol{W}_K$、$\boldsymbol{W}_V$均为线性变换矩阵。其次,经过线性转化后,$\boldsymbol{Q}$、$\boldsymbol{K}$、$\boldsymbol{V}$ 向量将分别被分为 h 个子向量,每个子向量的维度都为 d_h,其中 $d_h=d/h$,h 为注意力头数。经过分头操作后,使用缩放点积注意力机制,计算注意力权重 $\boldsymbol{A}$,通过加权求和值向量 $\boldsymbol{V}$ 得到注意力输出向量 $\boldsymbol{O}$,并将每个注意力头的输出重新合并,得到完整的注意力输出 $\boldsymbol{O}_{concat}$,即

$$\boldsymbol{A}=\mathrm{softmax}\left(\frac{\boldsymbol{Q}\boldsymbol{K}^{\mathrm{T}}}{\sqrt{d_h}}\right) \tag{5}$$

$$\boldsymbol{O}=\boldsymbol{A}\boldsymbol{V} \tag{6}$$

$$\boldsymbol{O}_{concat}=\mathrm{concat}(\boldsymbol{O}_1,\boldsymbol{O}_2,\cdots,\boldsymbol{O}_h) \tag{7}$$

最后,注意力通过线性变换和归一化后输出为向量 $\boldsymbol{O}_{out}$,参与多模态嵌入融合过程,即

$$\boldsymbol{O}_{out}=\mathrm{LayerNorm}(\boldsymbol{O}_{concat}\boldsymbol{W}_O+\boldsymbol{H}_I) \tag{8}$$

其中,$\boldsymbol{W}_O$ 是输出层权重矩阵,LayerNorm 表示层归一化操作。

2.4　实体对齐

在获取实体不同模态信息的嵌入之后,使用可训练的权重将实体的多个模态嵌入进行拼接为 $\boldsymbol{H}_E$,即

$$\boldsymbol{H}_E=\bigoplus_{m\in M}[\boldsymbol{W}_m\boldsymbol{H}_m] \tag{9}$$

其中,$\oplus$表示向量拼接操作,m 表示实体的不同模态,M 表示实体模态的集合。

为了增强模型对非对齐实体之间特征差异的捕捉能力,通过实体对齐对比学习框架[17]巩固多模态实体对齐的学习目标。对于种子实体对齐中的每个实体对(e_i^1,e_i^2),定义 $N_i^{ng}=\{e_j^1\mid\forall e_j^1\in\varepsilon_1,j\neq i\}\cup\{e_j^2\mid\forall e_j^2\in\varepsilon_2,j\neq i\}$ 为负对齐集合,并采用批内负采样策略将负对齐的抽样范围限定在批次 B 中,对齐概率分布为

$$p_m(e_i^1,e_i^2)=\frac{\gamma_m(e_i^1,e_i^2)}{\gamma_m(e_i^1,e_i^2)+\sum\limits_{e_j\in N_i^{ng}}\gamma_m(e_i^1,e_j)} \tag{10}$$

其中,$\gamma_m(e_i,e_j)=\exp\left((\boldsymbol{H}_E)_i^{\mathrm{T}}(\boldsymbol{H}_E)_j/\tau\right)$,$\tau$ 表示超参数。考虑到实体对齐一般为双向进行,只有两个实体互相为对方最相似的实体时才被视为对齐,因此对齐目标 L_m 被设置为

$$L_m=-E_{i\in B}\log[p_m(e_i^1,e_i^2)+p_m(e_i^2,e_i^1)]/2 \tag{11}$$

3　实验

3.1　实验设置

3.1.1　实验环境

使用 PyTorch 框架在配备了 Intel Core i7 - 13700F 处理器和 24 GB 显存的 NVIDIA RTX 4090 显卡的服务器上运行,实验代码环境为 Python 3.8 以及 Pytorch 2.3.1。

本实验中所有网络的隐藏层维度均设置为 300,各模态信息的初始化嵌入维度为 300,训练批量大小为 3 500,迭代次数为 250,学习率为 0.005,注意力头数 h 为 8,超参数 τ 设置为 0.1。

3.1.2　数据集设置

多模态猪病知识图谱 SDMKG 预先根据不同的知识来源被分为两个待对齐子图,用于训练实体对齐模型。其中,两个待对齐子图中共包含 612 个相似实体,组成 306 对种子对齐,在实体对齐学习中以比例 7∶2∶1划分为测试集、训练集以及验证集。

此外,为了验证第 2 节所提出实体对齐方法的泛化能力,在 DBP15K 数据集[19]上进行进一步验证,DBP15K 数据集包括 3 个跨语言子数据集,分别为 $\mathrm{DBP}_{\mathrm{ZH-EN}}$、$\mathrm{DBP}_{\mathrm{FR-EN}}$ 和 $\mathrm{DBP}_{\mathrm{JA-EN}}$,其中每个数据集包含 15 000 对种子对齐。虽然 DBP15K 为公共领域实体对齐数据集,但这些数据集与本文构造的猪病数据集在结构和理论上存在共性,具有参考价值。所有数据集统计结果如表 2 所示。

表 2　多模态数据集统计结果

Tab. 2　Statistical data of multi-modal knowledge graph datasets

数据集	实体数	三元组数	图像数
SDMKG	517	2 874	382
$\mathrm{DBP}_{\mathrm{ZH-EN}}$	38 960	165 556	37 143
$\mathrm{DBP}_{\mathrm{FR-EN}}$	39 654	221 720	28 032
$\mathrm{DBP}_{\mathrm{JA-EN}}$	39 594	170 698	36 062

由于在猪病等农业领域的多模态知识图谱在现实中存在图像缺失问题,本文通过随机删除图像,只保留固定比例图像模拟现实世界多模态知识图谱中存在的图像缺失现象。具体来说,设置

参数 R_{img}，表示数据集中拥有图像实体的比例，通过随机删除图像，使数据集中的实体只有 $R_{img}\times 100\%$ 的实体拥有图像描述，在实验中，R_{img} 取 0.05、0.2、0.4、0.6。对于缺少图像的实体，使用其他图像的平均值和标准差参数化的正态分布来随机初始化图像特征[17,19,32-33]。

3.1.3　评价指标

采用 Hits@1（H@1）、Hits@10（H@10）以及 Mean Reciprocal Rank（MRR）作为评价指标，其中，Hits@K 是指模型在检索到的前 K 个实体对齐结果中包含正确对齐结果的比例，MRR 用于衡量模型在所有查询中的平均反向排名这些指标能够有效衡量模型的准确性和有效性。

为了体现本文所提实体对齐方法的有效性，本文与 3 个优异的多模态实体对齐模型 EVA[19]、MCLEA[17]、UMAEA[21]在相同指标下进行对比。

3.2　主要实验

在不同的图像覆盖率 R_{img} 设置下观察模型实体对齐能力。主要实验结果如表 3 所示，其中，ITEA 表示本文所提出的多模态实体对齐方法。

表 3　主要实验结果

Tab.3　Main results of proposed model

数据集	模型	$R_{img}=0.05$			$R_{img}=0.2$			$R_{img}=0.4$			$R_{img}=0.6$		
		H@1	H@10	MRR	H@1	H@10	MRR	H@1	H@10	MRR	H@1	H@10	MRR
SDMKG	EVA	0.386	0.656	0.471	0.400	0.642	0.478	0.400	0.651	0.477	0.395	0.642	0.476
	MCLEA	0.405	0.604	0.475	0.432	0.586	0.491	0.427	0.600	0.488	0.400	0.614	0.465
	UMAEA	0.497	0.758	0.607	0.507	0.767	0.598	0.493	0.795	0.588	0.502	0.804	0.591
	ITEA	0.530	0.772	0.611	0.530	0.758	0.612	0.530	0.758	0.613	0.530	0.772	0.612
DBP_{ZH-EN}	EVA	0.623	0.878	0.715	0.624	0.878	0.716	0.623	0.875	0.714	0.625	0.876	0.717
	MCLEA	0.638	0.905	0.732	0.588	0.865	0.686	0.611	0.874	0.704	0.661	0.896	0.744
	UMAEA	0.720	0.938	0.800	0.727	0.941	0.806	0.727	0.941	0.806	0.758	0.951	0.829
	ITEA	0.872	0.975	0.911	0.873	0.975	0.911	0.874	0.975	0.912	0.875	0.976	0.914
DBP_{FR-EN}	EVA	0.624	0.895	0.720	0.624	0.895	0.720	0.626	0.898	0.721	0.634	0.900	0.728
	MCLEA	0.634	0.930	0.741	0.582	0.863	0.682	0.601	0.879	0.702	0.675	0.901	0.757
	UMAEA	0.727	0.956	0.813	0.733	0.960	0.817	0.746	0.961	0.828	0.790	0.968	0.857
	ITEA	0.963	0.996	0.976	0.963	0.996	0.976	0.9628	0.996	0.976	0.9642	0.9962	0.977
DBP_{JA-EN}	EVA	0.615	0.877	0.708	0.616	0.877	0.710	0.616	0.878	0.711	0.624	0.881	0.716
	MCLEA	0.599	0.897	0.706	0.579	0.846	0.675	0.613	0.867	0.703	0.686	0.898	0.761
	UMAEA	0.725	0.949	0.807	0.726	0.949	0.808	0.732	0.952	0.813	0.775	0.963	0.845
	ITEA	0.905	0.983	0.935	0.906	0.982	0.936	0.907	0.984	0.937	0.908	0.983	0.937

由表 3 可知，ITEA 在 SDMKG 数据集上 MRR 指标表现最佳，证明了该方法的有效性。另外，在其他 3 个公共数据集 DBP_{ZH-EN}、DBP_{FR-EN}、DBP_{JA-EN} 上，ITEA 的整体表现均优于现有模型，H@1 分别高出 0.152、0.236、0.180。尤其是在 DBP_{FR-EN} 数据集中，当数据集中包含图像的实体比例为 $R_{img}=\{0.05, 0.2, 0.4, 0.6\}$ 时，MRR 的提升幅度分别为 $\{0.163, 0.159, 0.148, 0.120\}$。这表明，ITEA 能够充分理解图像信息中与文本之间的关联，显著提升了模型的理解能力，提高了实体匹配的效率。此外，在 DBP_{ZH-EN}、DBP_{FR-EN}、DBP_{JA-EN} 3 个数据集上，ITEA 的 H@10 均有明显提升，进一步证明了该模型的泛化能力。在 SDMKG 中 H@10 未始终保持为最佳表现，但仍随着图像覆盖率的增加，H@10 逐渐提高，因此，ITEA 在 SDMKG 数据集上的提升效果略低于在公共数据集上的提升是由于 SDMKG 本身的体量较小，当数据集规模变大时，ITEA 仍然会表现出强大的多模态实体对齐能力。

综上所述，ITEA 展现出强大的抗干扰能力和良好的泛化性能，即使在特定领域的数据集上运行，仍能实现较好的多模态实体对齐效果。

3.3　消融实验

为了验证提出的“图像-文本”关联增强模块（以下简称 MHA 模块）能够有效地将与实体有关的文本描述关联到实体的图像中，通过取消 ITEA 中的 MHA 模块进行多模态实体对齐，完成消融实验。

消融实验在 SDMKG 数据集的结果如图 6 所示，横坐标中 w/o MHA 表示该消融实验，红色横线标注为 ITEA 的实体对齐效果。结果显示，在不同的图像覆盖率下，当在 ITEA 中取消 MHA 模块时，多模态实体对齐的 MRR 有所下降，但是随着图像覆盖率的提升，MRR 也随之提升，在 R_{img} 达到 0.6，即图像覆盖率达到 60% 时，不使用 MHA 模块的效果与使用 MHA 模块的效果一致。上述结果表明，

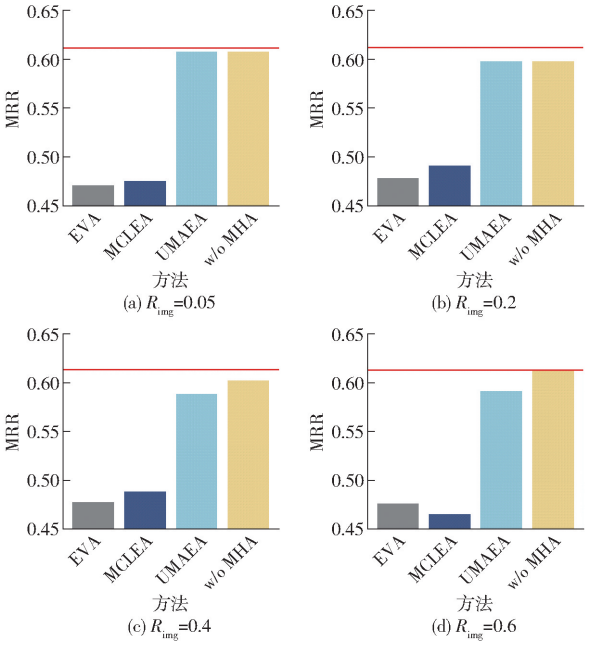

图 6 猪病数据集 SDMKG 上的消融实验结果

Fig. 6 Ablation experiment results on SDMKG

MHA 在面对图像数据少这一现实情况时,能够有效提高多模态实体对齐的综合效果。

为了进一步探究 MHA 模块的有效性,在 DBP15K 的 3 个公共数据集上进行消融实验,结果如表 4 所示。当不使用 MHA 模块时,ITEA 的实体对齐效果明显下降,即使在图像覆盖率达到 60% 时,MRR 仍较完整的 ITEA 实验效果低 0.087、0.120、0.093。这说明在大型数据集中,MHA 具有更大的多模态实体对齐潜力,进一步说明了 MHA 模块的有效性。

3.4 讨论

尽管本文为猪病的智能化管理构建了多模态知识图谱,但尚未利用所构建的知识图谱在实际猪病诊断任务中进行验证。在后续的研究工作中,将继续深入猪病知识图谱的应用研究,以不断优化猪病知识图谱的质量,实现猪病知识智能化服务。

表 4 DBP15K 数据集消融实验结果

Tab. 4 Results of ablation experiment on DBP15K

数据集	方法	R_{img}=0.05			R_{img}=0.2			R_{img}=0.4			R_{img}=0.6		
		H@1	H@10	MRR	H@1	H@10	MRR	H@1	H@10	MRR	H@1	H@10	MRR
DBP_{ZH-EN}	ITEA	0.872	0.975	0.911	0.873	0.975	0.911	0.874	0.975	0.912	0.875	0.976	0.914
	w/o MHA	0.706	0.933	0.789	0.715	0.937	0.796	0.727	0.940	0.806	0.757	0.949	0.827
DBP_{FR-EN}	ITEA	0.963	0.996	0.976	0.963	0.996	0.976	0.963	0.996	0.976	0.964	0.996	0.977
	w/o MHA	0.729	0.957	0.815	0.734	0.956 5	0.819	0.746 6	0.962	0.828	0.790 1	0.967 9	0.857
DBP_{JA-EN}	ITEA	0.905	0.983	0.935	0.906	0.982	0.936	0.907	0.984	0.937	0.908	0.983	0.937
	w/o MHA	0.701 9	0.946	0.791	0.714 4	0.944 5	0.797	0.727 4	0.950 2	0.810	0.773 6	0.960 5	0.844

4 结束语

通过融合两个异构数据源以获得一个高质量的多模态猪病知识图谱。首先,通过知识抽取和图像匹配实现初步构建两个多模态猪病数据集;其次,基于多模态信息学习实体表征以计算两个知识图谱之间的相等实体对,从而实现多模态猪病知识图谱融合。为解决视觉模态模糊问题,提出了“图像-文本”间关联增强的多模态融合方法,通过学习猪病文本信息与猪病图像信息之间的关联,以捕获猪病图像中的关键特征,从而达到增强实体向量表征的目的,实验结果证明了所提出的多模态融合方法能够在猪病实体对齐任务上取得优异性能。此外,现有研究表明,本文首次关注到多模态猪病知识图谱融合问题,对于推动猪病领域的智能化发展具有重要意义。本文方法同样适用于处理通用知识图谱场景,能够为多模态知识图谱融合提供新的思路借鉴。

参 考 文 献

[1] 姚绿. 绿色金融赋能生猪产业高质量发展影响研究[J]. 中国猪业, 2024, 19(5): 101-109.
YAO Lü. Research on the influence of high-quality development of green finance enabling pig industry[J]. China Swine Industry, 2024, 19(5): 101-109. (in Chinese)

[2] 沈明霞, 陈金鑫, 丁奇安, 等. 生猪自动化养殖装备与技术研究进展与展望[J]. 农业机械学报, 2022, 53(12): 1-19.
SHEN Mingxia, CHEN Jinxin, DING Qi'an, et al. Current situation and development trend of pig automated farming equipment application[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(12): 1-19. (in Chinese)

[3] 吴琼, 李志刚, 陈敏. 国内外农业农村信息化研究的知识图谱分析[J]. 中国农机化学报, 2024, 45(10): 215-222.
WU Qiong, LI Zhigang, CHEN Min. Knowledge map analysis of agricultural and rural informatization research at home and abroad[J]. Journal of Chinese Agricultural Mechanization, 2024, 45(10): 215-222. (in Chinese)

[4] 赵春江. 农业知识智能服务技术综述[J]. 智慧农业(中英文), 2023, 5(2): 126-148.

ZHAO Chunjiang. Agricultural knowledge intelligent service technology: a review[J]. Smart Agriculture, 2023, 5(2): 126 - 148. (in Chinese)

[5] 许瑞清, 许多, 张隽美, 等. 一种农业认知智能服务构建框架及其应用实践[J]. 南京大学学报(自然科学), 2024, 60(4): 613 - 624.
XU Ruiqing, XU Duo, ZHANG Junmei, et al. A framework for constructing agricultural cognitive intelligence services and its application practice[J]. Journal of Nanjing University (Natural Science), 2024, 60(4): 613 - 624. (in Chinese)

[6] STEINER T, VERBORGH R, TRONCY R, et al. Adding realtime coverage to the Google knowledge graph[C]// Proceedings of the 11th International Semantic Web Conference (ISWC), 2012: 65 - 68.

[7] 牛培宇,侯琛. 基于文本数据增强的中文水稻育种问句命名实体识别[J]. 农业机械学报,2024,55(8):333 - 343.
NIU Peiyu, HOU Chen. Named entity recognition in Chinese rice breeding questions based on text data augmentation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(8):333 - 343. (in Chinese)

[8] 袁立存, 周俊, 戈为溪, 等. 基于多模态知识图谱的水稻施肥期判别方法[J]. 农业机械学报, 2024, 55(9): 163 - 173.
YUAN Licun, ZHOU Jun, GE Weixi, et al. Rice fertilization period discrimination method based on multi-modal knowledge graph[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(9):163 - 173. (in Chinese)

[9] 陈华琼. 非洲猪瘟防治与治疗技术分析[J]. 安徽农学通报, 2024, 30(18): 37 - 41.
CHEN Huaqiong. Technical analysis of prevention and treatment of African swine fever[J]. Anhui Agricultural Science Bulletin, 2024, 30(18):37 - 41. (in Chinese)

[10] 刘广同, 曹淑楠, 杨万林, 等. 基于多传感器的方舱猪舍猪只采食行为分析系统[J]. 中国农机化学报, 2023, 44(9): 176 - 182,213.
LIU Guangtong, CAO Shunan, YANG Wanlin, et al. Development of feeding behavior analysis system for pigs in square cabin pig house based on multi-sensor[J]. Journal of Chinese Agricultural Mechanization, 2023, 44(9):176 - 182,213. (in Chinese)

[11] 杨亮, 王辉, 陈睿鹏, 等. 猪专用传感器研究进展[J]. 智能化农业装备学报(中英文), 2023, 4(2): 22 - 34.
YANG Liang, WANG Hui, CHEN Ruipeng, et al. Advances in research on pig-specific sensors[J]. Journal of Intelligent Agricultural Mechanization, 2023, 4(2):22 - 34. (in Chinese)

[12] 苑中旭, 李理, 何凡, 等. 融合思维链与知识图谱的中医问答模型[J/OL]. 计算机工程与应用: 1 - 10. http://kns.cnki.net/detail/11.2127.TP.20241015.1111.006.html.

[13] 刘政昊, 曾曦, 张志剑. 面向应急管理的金融突发事件事理知识图谱构建与分析研究[J]. 信息资源管理学报, 2022, 12(3): 137 - 151.
LIU Zhenghao, ZENG Xi, ZHANG Zhijian. Research on construction and analysis of financial emergencies knowledge graph with event logical for emergency management[J]. Journal of Information Resources Management, 2022, 12(3):137 - 151. (in Chinese)

[14] 陈雷, 周娜, 朱芃璇, 等. 农业知识图谱构建数据集[J]. 农业大数据学报, 2024, 6(1): 1 - 8.
CHEN Lei, ZHOU Na, ZHU Pengxuan, et al. A dataset for constructing agricultural knowledge graph[J]. Journal of Agricultural Big Data, 2024, 6(1):1 - 8. (in Chinese)

[15] 侯琛, 牛培宇. 农业知识图谱技术研究现状与展望[J]. 农业机械学报, 2024, 55(6): 1 - 17.
HOU Chen, NIU Peiyu. Review of research status and prospects of agricultural knowledge graphs[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(6): 1 - 17. (in Chinese)

[16] 张富, 杨琳艳, 李健伟, 等. 实体对齐研究综述[J]. 计算机学报, 2022, 45(6): 1195 - 1225.
ZHANG Fu, YANG Linyan, LI Jianwei, et al. An overview of entity alignment methods[J]. Chinese Journal of Computers, 2022, 45(6):1195 - 1225. (in Chinese)

[17] LIN Z, ZHANG Z, WANG M, et al. Multi-modal contrastive representation learning for entity alignment[C]// Proceedings of the 29th International Conference on Computational Linguistics (COLING), 2022: 2572 - 2584.

[18] CHEN L, LI Z, WANG Y, et al. MMEA: entity alignment for multi-modal knowledge graph[C]// Knowledge Science, Engineering and Management: 13th International Conference (KSEM), 2020: 134 - 147.

[19] LIU F, CHEN M, ROTH D, et al. Visual pivoting for (unsupervised) entity alignment[C]// Proceedings of the AAAI Conference on Artificial Intelligence (AAAI), 2021: 4257 - 4266.

[20] GUO H, TANG J, ZENG W, et al. Multi-modal entity alignment in hyperbolic space[J]. Neurocomputing, 2021, 461: 598 - 607.

[21] CHEN Z, GUO L, FANG Y, et al. Rethinking uncertainly missing and ambiguous visual modality in multi-modal entity alignment[C]// International Semantic Web Conference. Springer (ISWC), 2023: 121 - 139.

[22] 沈子雷, 杜永强. 基于 BERT 的农作物命名实体识别模型研究[J]. 计算机应用与软件, 2024, 41(6): 223 - 229.
SHEN Zilei, DU Yongqiang. BERT-based named entity recognition model for agricultural domains[J]. Computer Applications and Software, 2024, 41(6):223 - 229. (in Chinese)

[23] 唐闻涛, 胡泽林. 农业知识图谱研究综述[J]. 计算机工程与应用, 2024, 60(2): 63 - 76.
TANG Wentao, HU Zelin. Survey of agricultural knowledge graph[J]. Computer Engineering and Applications, 2024, 60(2):63 - 76. (in Chinese)

[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.