doi:10.6041/j.issn.1000-1298.2025.07.054

基于知识图谱和语义与结构融合的羊病诊断方法

李书琴　高云帆
（西北农林科技大学信息工程学院，陕西杨凌 712100）

摘要：针对疾病诊断模型仅依靠语义特征而缺少结构特征，导致弱化诊断效果的问题，本文提出了基于知识图谱和语义与结构融合的羊病诊断方法。该方法采用双向门控循环单元（Bidirectional gated recurrent unit，BiGRU）获取症状文本的语义特征，采用图卷积网络（Graph convolutional network，GCN）获取症状知识图谱中潜在的结构特征。为更好地融合语义特征和结构特征，引入改进的注意力特征融合（Attentional feature fusion，AFF）模块。在羊病症状数据集 Sheep 上进行实验，结果表明本文模型的准确率、精确率、召回率、F1 值、平均倒数排名分别达到 96.86%、97.73%、97.32%、97.25%、97.49%，与 TextCNN、TextRCNN、TextRNN、DPCNN、LASA、HSAN－capsule、DCDKG、CNN－BiLSTM－Attention 等模型对比，准确率提升 0.19～1.76 个百分点，精确率提升 0.18～0.84 个百分点，召回率提升 0.14～1.21 个百分点，F1 值提升 0.21～1.50 个百分点，平均倒数排名提升 0.15～0.23 个百分点。同时在公开数据集 Dxy 和 Muzhi 上进行实验，模型表现出较好的鲁棒性。为增强疾病诊断的可解释性，本文提出了改进的基于梯度的显著性方法以解释诊断结果。该研究提出的融合语义和结构特征的方法有效提高了疾病诊断准确率，为羊病诊断提供技术支撑。

关键词：羊病诊断；知识图谱；图卷积网络；可解释性；自然语言处理；多模态融合
中图分类号：TP391.1　　**文献标识码**：A　　**文章编号**：1000-1298(2025)07-0575-10　　**OSID**：

Diagnosis Method of Sheep Disease Based on Knowledge Graph and Fusion of Semantics and Structure

LI Shuqin　GAO Yunfan
(*College of Information Engineering*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*)

Abstract: Aiming at the problem of weakened diagnostic effectiveness caused by disease diagnosis models relying solely on semantic feature while lacking structural feature, a diagnosis method of sheep disease was proposed based on knowledge graph and fusion of semantics and structure. Bidirectional gated recurrent unit (BiGRU) was utilized to extract semantic feature from symptom texts, and graph convolutional network (GCN) was utilized to capture latent structural feature from the symptom knowledge graph. To better integrate semantic and structural features, an improved attentional feature fusion (AFF) module was introduced. Experimental results on the sheep disease symptom dataset demonstrated that the proposed model achieved the accuracy, precision, recall, F1 score, and mean reciprocal rank of 96.86%, 97.73%, 97.32%, 97.25%, and 97.49%, respectively. Compared with models such as TextCNN, TextRCNN, TextRNN, DPCNN, LASA, HSAN－capsule, DCDKG, and CNN－BiLSTM－Attention, the accuracy was improved by at least 0.19 percentage points and up to 1.76 percentage points, the precision was improved by at least 0.18 percentage points and up to 0.84 percentage points, the recall was improved by at least 0.14 percentage points and up to 1.21 percentage points, the F1 score was improved by at least 0.21 percentage points and up to 1.50 percentage points, and the mean reciprocal rank was improved by at least 0.15 percentage points and up to 1.23 percentage points. Additionally, experiments on the public datasets Dxy and Muzhi validated the model's robustness. To enhance the interpretability of disease diagnosis, an improved gradient-based saliency method was proposed to explain diagnostic results. The method of fusing semantic and structural features effectively improved disease diagnosis accuracy, providing technical support for sheep disease diagnosis.

Key words: sheep disease diagnosis; knowledge graph; graph convolutional network; interpretability; natural language processing; multimodal fusion

收稿日期：2024－04－10　修回日期：2024－05－20
基金项目：国家重点研发计划项目(2022YFD1300200)
作者简介：李书琴(1965—)，女，教授，博士生导师，主要从事农业信息化与智能信息系统研究，E-mail：lsq_cie@nwsuaf.edu.cn

0 引言

随着羊养殖业向规模化方向发展,高水平兽医人才却未能同步增长,导致羊场在羊病诊断能力上有缺陷,对经济收益造成负面影响。借助羊病诊断系统可以有效弥补兽医专家紧缺的问题,提升羊只健康化管理水平。

早期的疾病诊断系统以专家系统为基础。专家系统(Expert system,ES)的核心是知识库和推理机。聂艳召等[1]采用特征向量空间的加权检索算法,提出基于案例推理的羊病诊断方法。谭文学等[2]设计重权关联证据预测加权不确定性推理和主观贝叶斯推理算法,采用双推理机核诊断山羊疾病,准确率达到90%。秦宏宇等[3]建立基于模糊规则提升理论的推理机制,在马病数据集上准确率达到92.28%。然而,基于专家系统的疾病诊断模型存在局限,需要人工定义大量专家知识,规则维护成本高且不易扩展,在处理复杂疾病诊断任务时能力受到限制。

近年来,深度学习在疾病诊断领域取得一系列成果[4]。胡满满等[5]采用卷积神经网络模型,引入动态采样和迁移学习技术,在肠功能紊乱和细菌性感染疾病诊断准确率分别达到71.67%和74.54%。MEN等[6]采用时间感知和注意力机制的长短期记忆网络模型实现疾病多标签分类,在电子病历数据集上F1值达到87.9%。徐畅等[7]提出基于贝叶斯优化的模型,番茄病害诊断准确率达到89.11%。丁俊琦等[8]提出数据融合与注意力机制优化的作物病害诊断模型,在植物电子病历数据上准确率达到95.82%。尽管基于深度学习的疾病诊断模型具有良好的泛化能力,然而缺乏整合专家诊断知识的能力,难以揭示疾病与症状之间的内在联系。

随着知识图谱技术的发展,一些研究将知识图谱作为诊断模型的背景知识,以提高疾病诊断效果。董丽丽等[9]引入医学知识图谱,将疾病特征词向量与相应知识实体向量作为卷积神经网络的多通道输入,诊断准确率达到85.7%。翟增林等[10]采用图卷积网络聚合知识图谱信息,与词向量特征拼接作为长短期记忆网络的多通道输入,诊断精确率与召回率达到94.29%和88.26%。WANG等[11]提出了BLCKG模型,从病情报告中提取显性特征,再从疾病知识图谱中提取隐性特征,将显性和隐性特征输入BiLSTM-CNN实现疾病诊断,准确率达到94.57%。尽管知识图谱中包含丰富的结构特征信息,然而目前基于知识图谱的疾病诊断模型尚未能有效地将文本中的语义特征与知识图谱中的结构特征进行深度融合。同时,当前的疾病诊断模型普遍存在可解释性不足问题,难以为诊断结果提供依据,影响了这些模型在临床应用中的广泛接受度。

基于以上问题,本文提出基于知识图谱和语义与结构融合的羊病诊断模型。首先,将症状文本转换为词向量,采用双向门控循环单元(Bidirectional gated recurrent unit,BiGRU)提取语义特征,采用图卷积网络(Graph convolutional network,GCN)提取知识图谱中的结构特征。最后,通过改进的注意力特征融合(Attentional feature fusion,AFF)模块有效融合语义特征与结构特征。为进一步增强疾病诊断的可解释性,本文提出一种改进的基于梯度的显著性方法以解释诊断结果。

1 模型结构

基于知识图谱和语义与结构融合的羊病诊断模型由编码层、特征提取层、特征融合层、输出层4部分组成,模型结构如图1所示。其中,编码层包括词向量编码和图结构编码。特征提取层包括用于语义特征提取的BiGRU模块和用于结构特征提取的GCN模块。特征融合层将语义和结构两个特征通

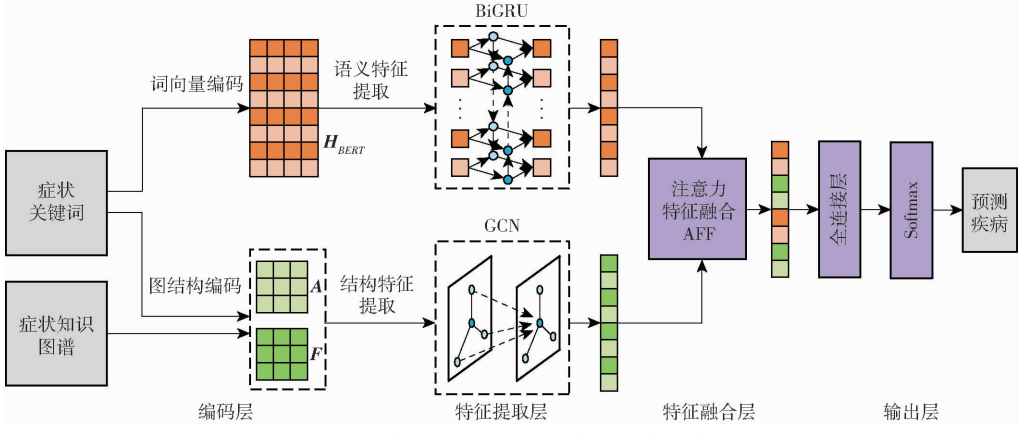


图1 基于知识图谱和语义与结构融合的羊病诊断模型结构图

Fig. 1 Structural diagram of sheep disease diagnosis model based on knowledge graph and fusion of semantics and structure

过改进的 AFF 模块进一步融合。输出层使用全连接层和 Softmax 函数计算羊病的概率，完成羊病诊断任务。

1.1　编码层

1.1.1　词向量编码

羊病描述文本是对病羊表型症状的描述文本，包含若干个症状关键词。使用 BERT(Bidirectional encoder representation from transformers)预训练模型将症状关键词 $s=(c_1,c_2,\cdots,c_{len(s)})$ 进行编码，将症状关键词按照字符逐个编码并求和，转换为带有特征信息的词向量矩阵 $\boldsymbol{H}_{BERT}$，计算公式为

$$\boldsymbol{H}_{BERT}=\frac{\sum_{i=1}^{\mathrm{len}(s)}\mathrm{Bert}(c_i)}{\mathrm{len}(s)} \tag{1}$$

式中　$\mathrm{len}(s)$——症状关键词 s 的字符长度

c_i——症状关键词 s 中第 i 个字符

$\mathrm{Bert}(\ )$——BERT 预训练模型

1.1.2　图结构编码

根据羊病和症状信息构建症状知识图谱，将知识图谱中图结构信息向量转为矩阵，构建特征矩阵 $\boldsymbol{F}$ 和邻接矩阵 $\boldsymbol{A}$。

特征矩阵 $\boldsymbol{F}$ 表示疾病的症状信息，该矩阵的每一行表示疾病 d_i 与对应症状 s_j 信息，计算公式为

$$\boldsymbol{F}[i][j]=\begin{cases}1 & (s_j\in d_i)\\ 0 & (s_j\notin d_i)\end{cases} \tag{2}$$

邻接矩阵 $\boldsymbol{A}$ 表示疾病之间的连接关系，该矩阵的元素 $\boldsymbol{A}[i][j]$ 表示疾病 d_i 与 d_j 之间的相关程度，疾病 d_i 与 d_j 的症状集合分别为 S_i 和 S_j，使用 Jaccard 相似系数计算节点 i 与节点 j 之间的权重，计算公式为

$$\boldsymbol{A}[i][j]=\mathrm{Jaccard}(i,j)=\frac{|S_i\cap S_j|}{|S_i\cup S_i|} \tag{3}$$

1.2　特征提取层

1.2.1　语义特征提取

语义特征提取任务采用 BiGRU 模块。BiGRU 擅长提取时序信息，由正向 GRU 和反向 GRU 组成，分别从正向和反向两个顺序提取文本中的序列特征。GRU 单向传播计算的相关公式为

$$\boldsymbol{r}_t=\sigma(\boldsymbol{W}_r[\boldsymbol{h}_{t-1},\boldsymbol{x}_t]+\boldsymbol{b}_r) \tag{4}$$

$$\boldsymbol{z}_t=\sigma(\boldsymbol{W}_z[\boldsymbol{h}_{t-1},\boldsymbol{x}_t]+\boldsymbol{b}_z) \tag{5}$$

$$\widetilde{\boldsymbol{h}}_t=\tanh(\boldsymbol{W}_h[\boldsymbol{r}_t\circ\boldsymbol{h}_{t-1},\boldsymbol{x}_t]+\boldsymbol{b}_h) \tag{6}$$

$$\boldsymbol{h}_t=(1-\boldsymbol{z}_t)\circ\boldsymbol{h}_{t-1}+\boldsymbol{z}_t\circ\widetilde{\boldsymbol{h}}_t \tag{7}$$

式中　$\boldsymbol{r}_t$——重置门状态

$\boldsymbol{z}_t$——更新门状态

$\widetilde{\boldsymbol{h}}_t$——候选隐藏状态

$\boldsymbol{x}_t$——当前时刻输入

$\boldsymbol{h}_{t-1}$——前一时刻状态

$\boldsymbol{h}_t$——当前时刻状态

$\boldsymbol{W}_r$、$\boldsymbol{W}_z$、$\boldsymbol{W}_h$——权重矩阵

$\boldsymbol{b}_r$、$\boldsymbol{b}_z$、$\boldsymbol{b}_h$——偏置向量

重置门状态 $\boldsymbol{r}_t$ 决定前一时刻状态是否被重置，更新门状态 $\boldsymbol{z}_t$ 控制前一时刻状态 $\boldsymbol{h}_{t-1}$ 和候选隐藏状态 $\widetilde{\boldsymbol{h}}_t$ 的平衡。

经过预处理模型 BERT 进行词向量编码，得到羊病症状的语义特征矩阵 $[\boldsymbol{H}_1^{BERT},\boldsymbol{H}_2^{BERT},\cdots,\boldsymbol{H}_n^{BERT}]$，输入 BiGRU 得到隐藏特征向量 $\boldsymbol{H}=[\boldsymbol{h}_1,\boldsymbol{h}_2,\cdots,\boldsymbol{h}_n]$，其中 $\boldsymbol{h}_t=(\overrightarrow{\boldsymbol{h}_t}+\overleftarrow{\boldsymbol{h}_t})/2$，即将正向和反向的隐藏向量取平均值获得。

1.2.2　结构特征提取

结构特征的提取任务采用 GCN 模块。GCN 与图卷积网络(Convolutional neural network，CNN)均为特征提取网络。CNN 用于图像特征提取任务，图像是规则的欧氏空间。GCN 是 CNN 在非欧氏空间的扩展，是一种处理图结构数据的卷积网络[12]。知识图谱本身包含丰富的图结构信息，因此 GCN 可以有效提取知识图谱中的图结构信息，从而获取知识的结构特征。

图卷积网络通过聚合邻居节点信息以更新当前节点特征。如图 2 所示，对于羊病 d，通过聚合周围邻居节点 s_i，将症状的特征融合，公式为

$$\boldsymbol{G}_i^{k+1}=\sum_{i\in neighbor(d)}\boldsymbol{A}_{ij}\boldsymbol{G}_i^k \tag{8}$$

式中　$\boldsymbol{G}_i^k$——上一步节点特征

$\boldsymbol{G}_i^{k+1}$——新的节点特征

$\boldsymbol{A}_{ij}$——邻接矩阵中第 i 行第 j 列元素

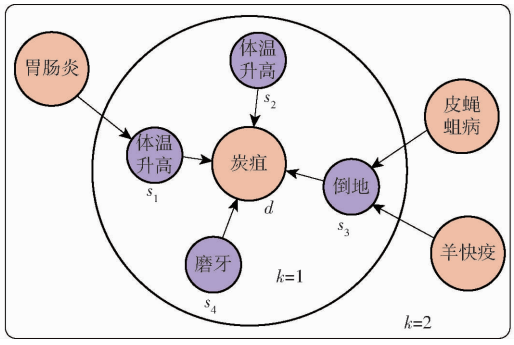


图 2　图卷积示意图

Fig. 2　Schematic of graph convolution

邻接矩阵需要考虑自身特征，在图中每个节点增加自连接，在邻接矩阵加上单位矩阵 $\boldsymbol{I}_n$，公式为

$$\widehat{\boldsymbol{A}}=\boldsymbol{A}+\boldsymbol{I}_n \tag{9}$$

节点之间的连接数量不同，节点度数大的计算特征总和会越来越大，节点度数小则相反。为避免

训练过程中造成梯度爆炸或梯度消失，利用度矩阵 $\widetilde{\boldsymbol{D}}$ 对自连接的邻接矩阵进行对称归一化后，与权重矩阵 $\boldsymbol{W}^{(k)}$ 相乘，与偏置矩阵 $\boldsymbol{b}^{(k)}$ 相加，再经过激活函数 Sigmoid，得到下一层节点特征，公式为

$$\boldsymbol{G}^{(k+1)}=f(\boldsymbol{G}^{(k)},\boldsymbol{A})=\sigma(\widetilde{\boldsymbol{D}}^{-0.5}\widetilde{\boldsymbol{A}}\widetilde{\boldsymbol{D}}^{-0.5}\boldsymbol{G}^{(k)}\boldsymbol{W}^{(k)}+\boldsymbol{b}^{(k)}) \tag{10}$$

1.3 特征融合层

特征融合层的任务是将语义特征和结构特征融合。由于注意力特征融合模块[13]的特征融合对象是二维图像，本文将其改进为特征融合对象是一维文本的模块，结构如图 3 所示。注意力特征融合模块对 BiGRU 提取的语义特征和 GCN 提取的结构特征融合，将语义特征向量 $\boldsymbol{H}$ 和结构特征向量 $\boldsymbol{G}$ 采用 AFF 模块获得融合特征向量 $\boldsymbol{D}_{aff}$，公式为

$$L(\boldsymbol{X})=\mathrm{Conv}_2(\mathrm{ReLU}(\mathrm{Conv}_1(\boldsymbol{X}))) \tag{11}$$

$$g(\boldsymbol{X})=\mathrm{Pool}(\mathrm{Conv}_2(\mathrm{ReLU}(\mathrm{Conv}_1(\boldsymbol{X})))) \tag{12}$$

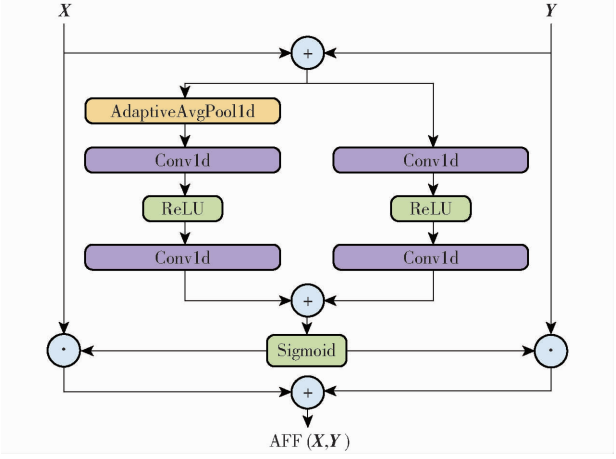


图 3 注意力特征融合模块结构图

Fig. 3 Structural diagram of attentional feature fusion module

$$M(\boldsymbol{X})=\sigma(L(\boldsymbol{X})+g(\boldsymbol{X})) \tag{13}$$

$$AFF(\boldsymbol{X},\boldsymbol{Y})=M(\boldsymbol{X}+\boldsymbol{Y})\boldsymbol{X}+(1-M(\boldsymbol{X}+\boldsymbol{Y}))\boldsymbol{Y} \tag{14}$$

$$\boldsymbol{D}_{aff}=AFF(\boldsymbol{H},\boldsymbol{G}) \tag{15}$$

式中 $\boldsymbol{X}$、$\boldsymbol{Y}$——输入的特征向量

$L(\boldsymbol{X})$——局部特征注意力函数

$g(\boldsymbol{X})$——全局特征注意力函数

$M(\boldsymbol{X})$——多尺度通道注意力模块

$AFF(\boldsymbol{X},\boldsymbol{Y})$——注意力特征融合模块

Conv_1、Conv_2——1×1 的点卷积

Conv_1 将输入特征通道数 768 减少为 96，Conv_2 将特征通道数恢复为 768。

1.4 输出层

输出层的任务是根据融合特征，输出预测的羊病类型。融合特征向量 $\boldsymbol{D}_{aff}$ 经过全连接层获得长度为 k 的特征向量 $\boldsymbol{D}$，使用 Softmax 函数预测每种羊病类型的概率，公式为

$$\boldsymbol{D}=\mathrm{Dense}(\boldsymbol{D}_{aff}) \tag{16}$$

$$pred_k=\mathrm{softmax}(\boldsymbol{D}_k)=\frac{\exp(\boldsymbol{D}_k)}{\sum_{i=1}^{n}\exp(\boldsymbol{D}_i)} \tag{17}$$

式中 $pred_k$——第 k 种羊病类型概率

n——羊病类型总数

2 实验

2.1 实验数据

2.1.1 羊病症状知识图谱构建

本文提出的羊病诊断模型引入羊病症状知识图谱作为知识。本文构建的知识图谱主要包括数据采集、实体识别与链接、三元组提取 3 个步骤，如图 4 所示。

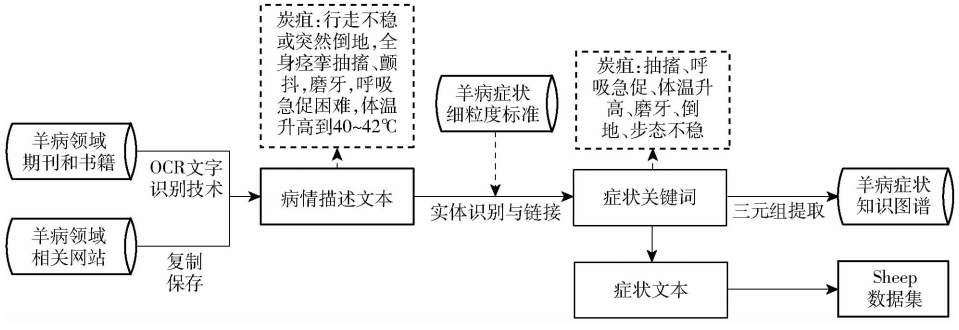


图 4 羊病症状知识图谱构建流程图

Fig. 4 Flowchart for construction of sheep disease symptom knowledge graph

所构建的羊病症状知识图谱的数据来源为羊相关网站（养羊网、百度百科）、期刊（《中兽医医药杂志》）和书籍（《羊病防治及安全用药》《羊病诊治实用技术》《羊病临床诊疗技术与典型医案》《羊生产学》《羊病类症鉴别与诊治彩色图谱》）。对于电子化的期刊和网站，可直接对病情描述文本进行复制与保存；而对于纸质化的书籍，采用光学字符识别（Optical character recognition，OCR）技术将书籍的字符转化为电子文档，获得病情描述文本。

参考中文症状知识库[14]、养羊网和百度百科关

于羊症状的分类标准，划定羊病症状细粒度标准，如图 5 所示。细粒度标准主要分为两级，一级标准为大类划分，划分出“一般检查”“消化系统检查”“运动系统检查”“其他器官检查”和“其他”共 5 类；二级标准为细致划分，例如对于一级类型“消化系统检查”，再划分出“采食”“排粪次数”“粪便形状”“粪便气味”等类型。

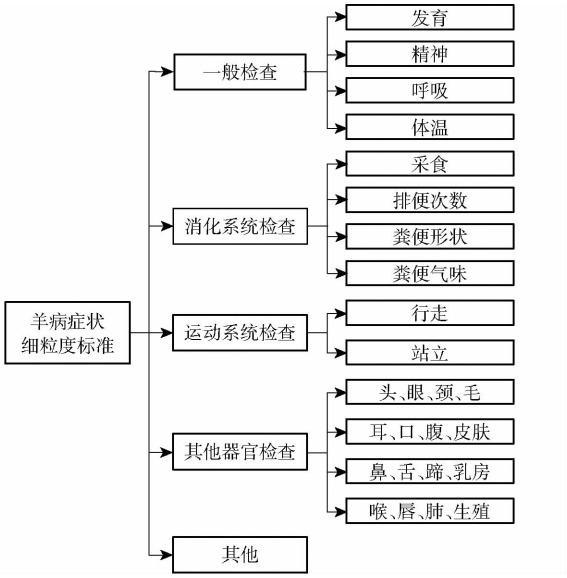


图 5　羊病症状细粒度标准

Fig. 5　Fine-grained standard for sheep disease symptom

按照羊病症状细粒度标准，从病情描述文本采用词典匹配方式进行实体识别与链接，获得症状关键词。例如对于“步态不稳”“行走不稳”“步态蹒跚”“步态强拘”“运步强拘”“行步困难”等语义相近的症状关键词，统一设定为“步态不稳”，并存储到哈希表中。人工设定好哈希表后，遍历所有病情描述文本，根据哈希表的键值对提取出病情描述文本包含的症状。存在部分症状描述较为罕见的情况，例如对于描述体温的症状“体温高至 40 ~ 41℃”，由于症状描述带有数字，因而难以在哈希表中匹配，因此对哈希表抽取后的结果进行人工校对，将遗漏的症状补齐。

将症状关键词转化为 json 格式的症状文本，构成 Sheep 数据集。将疾病与症状相关联，组成三元组并提取，最终构建羊病症状知识图谱。包含 13 998 个实体和 12 398 个关系。羊病症状知识图谱具有丰富的图结构特征信息，不同的疾病具有相同的症状。如图 6 所示，“食盐中毒”“炭疽”“皮蝇蛆病”3 种疾病均具有“不安”症状。

2.1.2　实验数据集

在 Sheep、Dxy[15]、Muzhi[16]3 个数据集上验证本文模型，数据集包含的疾病、症状、训练集、测试集数量如表 1 所示。数据集中每条数据的内容为症状列表，相应标签为疾病名称。构建 Dxy 和 Muzhi 数据集的知识图谱步骤与羊病症状知识图谱构建步骤相同。

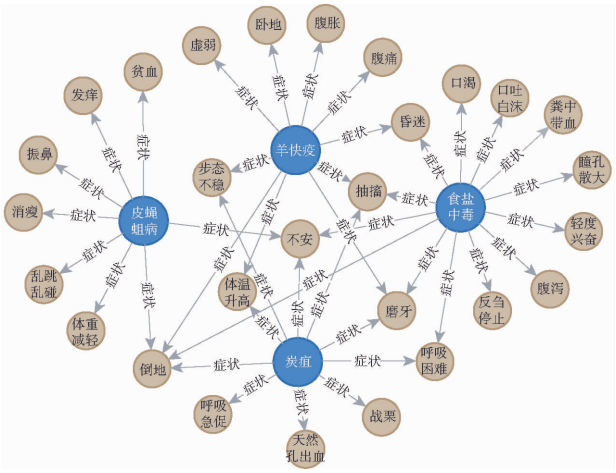


图 6　羊病症状知识图谱可视化结果

Fig. 6　Sheep disease symptom knowledge graph visualization result

表 1　数据集样本数量

Tab. 1　Sample size of datasets

数据集	疾病	症状	训练集	测试集
Sheep	92	118	2 096	510
Dxy	5	41	423	104
Muzhi	4	66	568	142

Sheep 数据集由羊病症状文本组成。该数据集包含“炭疽”“羊快疫”“巴氏杆菌病”等 92 种疾病类型的羊病症状数据集。

Dxy 数据集来自中国在线医疗平台丁香园，该平台提供在线问诊和远程医疗服务。该数据集包含“过敏性鼻炎”“上呼吸道感染”“肺炎”“小儿手足口病”“小儿腹泻”5 种疾病类型。

Muzhi 数据集来自中国在线医疗平台拇指医生，该网站是百度打造的医生与患者实时沟通平台。该数据集包括“上呼吸道感染”“小儿支气管炎”“小儿腹泻”“小儿消化不良”4 种疾病类型。

2.2　实验设置

2.2.1　评价指标

实验采用准确率（Accuracy，Acc）、精确率（Precision，P）、召回率（Recall，R）、F1 值（F1 score）和正确答案的平均倒数排名（Mean reciprocal rank，MRR）作为评价指标。

2.2.2　实验环境

实验基于 64 位 Ubuntu 20.04 操作系统，显卡为 RTX 3090，Cuda 版本为 11.1，配置 Python 版本为 3.7，采用深度学习框架 Pytorch 1.8.0 搭建网络模型。

2.2.3 模型参数

采用 SGD 随机梯度下降算法,学习率初始设置为 0.001,采用 CosineAnnealingLR 余弦退火调度器,损失函数采用 CrossEntropyLoss 交叉熵损失函数,训练轮次均设置为 100,BERT 预训练模型版本选择 bert-base-chinese。

3 结果与分析

3.1 模型对比

选择 TextCNN[17]、TextRCNN[18]、TextRNN[19]、DPCNN[20]、LASA[21]、HSAN-capsule[22]、DCDKG[11]和 CNN-BiLSTM-Attenion[23]为对比模型。部分模型中的词向量编码模块不再采用 word2vec[24],所有模型的词向量编码模块均采用 BERT[25]预训练模型。表 2 列出了对比实验结果。

由表 2 可知,TextCNN 模型由于卷积核的视野有限,在文本较长的 Sheep 数据集上表现不如其他模型,准确率为 96.27%;而在文本长度较短的 Dxy 和 Muzhi 数据集上表现较好,准确率分别为 81.73% 和 71.83%。TextRCNN 模型将双向 RNN 与池化层结合,相比 TextCNN 在 Sheep 数据集上有所提升,但是在数据量较小的 Dxy 数据集上表现较差,准确率仅为 76.92%。TextRNN 模型采用 RNN 信息共享机制,但由于仅使用了最后一个时间步的输出,包含信息量较少,各个指标表现较差。DPCNN 模型采用深度金字塔卷积神经网络,深度的卷积层能够捕捉文本中更多的信息,在 Muzhi 数据集上达到了较好的效果,准确率达到 73.94%,精确率达到 74.41%;而在 Dxy 数据集上的表现较差可能是由于数据量较小,导致深度卷积网络难以学习数据的复杂性。LASA 模型通过使用标签语义注意力机制分配每个词的权重,以评估每个词对当前标签的重要程度,在 Dxy 和 Muzhi 数据集上表现较好,准确率分别达到 81.73% 和 72.54%。HSAN-capsule 模型采用胶囊网络并引入注意力机制,在 Sheep 数据集上效果较好,准确率达到 95.69%;而在 Muzhi 数据集上准确率较低,仅为 70.42%。DCDKG 模型融入知识图谱中的隐性特征,在各个数据集上的表现均较好,准确率分别达到 95.29%、81.73% 和 73.24%。CNN-BiLSTM-Attention 模型融合了不同层次的语义信息,采用多标签注意力机制,在 Dxy 数据集上准确率达到 82.69%,精确率达到 84.35%。

本文模型融合语义与结构两种特征,采用 BiGRU 从症状文本中提取语义特征,采用 GCN 从症状知识图谱中提取结构特征,与仅依赖文本的语义特征分析的其他模型相比,本文模型综合考虑结构特征,能够捕获更丰富的信息。同时,引入注意力特征融合模块,能够有效地将语义与结构特征融合,提升模型性能。本文模型在 Sheep、Dxy 和 Muzhi 这 3 个数据集上的准确率分别高达 96.86%、82.69% 和 73.94%,均优于现有模型,验证了融合语义特征与结构特征方法在提升疾病诊断准确率方面的显著优势。在精确率、召回率、F1 值和平均倒数排名等其他评价指标中,本文模型在多数情况下也能够达到最佳性能,验证了本文模型在不同疾病数据集上的鲁棒性和泛化能力。

表 2 模型对比实验结果

Tab. 2 Model comparison experimental results %

模型	Sheep					Dxy					Muzhi				
	Acc	*P*	*R*	F1 值	MRR	Acc	*P*	*R*	F1 值	MRR	Acc	*P*	*R*	F1 值	MRR
TextCNN	96.27	97.49	96.92	96.82	97.29	81.73	83.31	82.00	82.36	89.81	71.83	72.64	71.62	71.60	84.86
TextRCNN	96.67	97.47	97.18	97.04	96.94	76.92	78.96	76.99	77.33	86.78	71.83	71.83	71.07	70.97	85.09
TextRNN	95.69	97.03	96.51	96.43	96.98	81.73	83.24	82.16	82.61	89.90	70.42	70.34	69.95	69.71	84.62
DPCNN	96.47	97.55	96.78	96.77	97.34	76.92	79.27	77.16	77.57	87.66	73.94	74.41	72.91	72.91	86.21
LASA	95.10	96.89	96.11	95.99	96.62	81.73	82.71	82.00	82.23	89.66	72.54	73.32	71.34	71.53	85.63
HSAN-capsule	95.69	97.12	96.51	96.42	96.99	81.73	83.20	82.00	82.44	89.65	70.42	70.13	69.78	69.60	83.57
DCDKG	95.29	96.93	96.11	95.75	96.26	81.73	82.68	82.00	82.29	89.85	73.24	73.49	72.45	72.42	85.92
CNN-BiLSTM-Attention	95.69	97.01	96.51	96.38	97.11	82.69	84.35	82.83	83.20	90.06	72.54	72.64	71.62	71.60	85.27
本文模型	96.86	97.73	97.32	97.25	97.49	82.69	84.15	83.00	83.24	90.10	73.94	74.16	73.11	73.10	86.27

各模型准确率曲线如图 7 所示。本文模型在

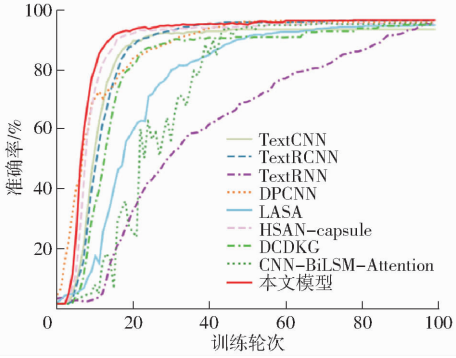


图 7 准确率曲线

Fig. 7 Accuracy curves

20 轮后趋于收敛，相比其他模型收敛速度较快，充分体现了本文模型训练效率优势。无论是模型性能还是训练速度均证明了本文模型采用的语义特征和结构特征融合方法的有效性和优越性。

采用 t－SNE[26]（t－distributed stochastic neighbor embedding）方法将语义特征和结构特征融合后的特征向量进行可视化，通过为不同疾病类型的数据点分配不同颜色进行区分，直观地观察这些数据点在二维空间中的分布情况。本文模型在 Sheep、Dxy 和 Muzhi 数据集上特征向量可视化效果如图 8 所示。图 8a 展示了 Sheep 数据集中筛选的 12 种常见疾病类型分布情况，旨在确保图像的清晰度。由图 8a 可知，大部分数据点在图中展现出较高的区分度，仅有“羊口疮”类中少部分点相对分散，未能形成紧密的聚类。图 8b 展示了 Dxy 数据集中 5 种疾病类型分布情况，“肺炎”与“上呼吸道感染”数据点存在部分混淆。图 8c 展示了 Muzhi 数据集中 4 种疾病类型分布情况，“上呼吸道感染”与“小儿支气管炎”、“小儿腹泻”与“小儿消化不良”数据点存在重叠情况。通过 t－SNE 可视化分析表明，本文模型得到的特征向量展现出较好的区分效果。

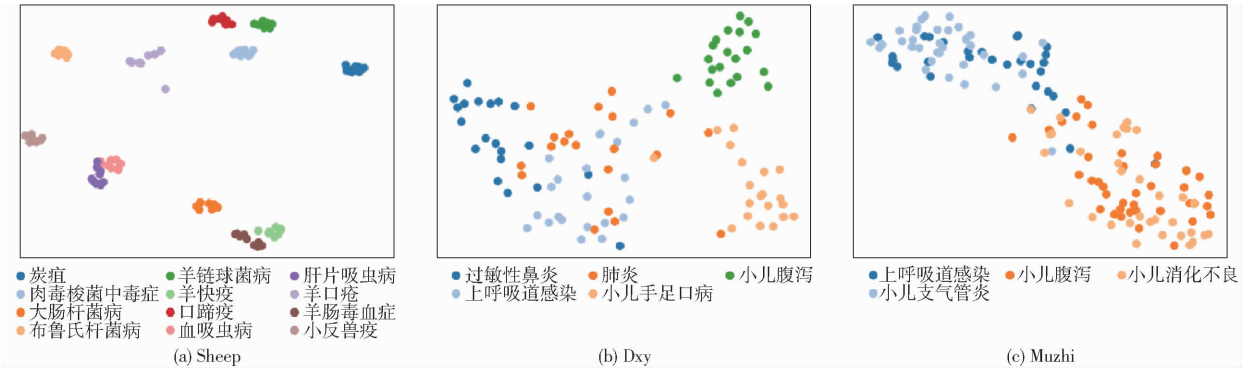


图 8　特征向量的 t－SNE 可视化

Fig. 8　Visualization of feature vectors using t－SNE

3.2　消融实验

为深入探究本模型在疾病诊断中的效果，设计消融实验以考察基于语义特征的 BiGRU 模块、基于结构特征的 GCN 模块以及改进的 AFF 模块，旨在评估每个模块对整体性能的贡献，实验结果如表 3 所示。

表 3　消融实验结果

Tab. 3　Ablation experiment results　　%

实验	BiGRU	GCN	AFF	Sheep					Dxy					Muzhi				
				Acc	*P*	*R*	F1 值	MRR	Acc	*P*	*R*	F1 值	MRR	Acc	*P*	*R*	F1 值	MRR
1	√	×	×	95.88	97.11	96.38	96.34	97.02	81.73	83.31	82.00	82.26	89.87	72.54	72.23	71.90	71.73	85.83
2	×	√	×	93.92	96.34	95.04	94.91	96.14	76.92	78.46	77.33	77.43	87.71	64.79	64.51	64.27	63.81	80.29
3	√	√	×	96.27	97.33	96.92	96.81	97.25	81.73	83.28	82.00	82.39	89.95	73.23	72.90	72.66	72.51	86.02
4	√	√	√	96.86	97.73	97.32	97.25	97.49	82.69	84.15	83.00	83.24	90.10	73.94	74.16	73.11	73.10	86.27

注：“√”表示添加，“×”表示未添加。

消融实验结果显示，基于语义特征的 BiGRU 模块的表现优于基于结构特征的 GCN 模块，这说明在疾病诊断任务中语义特征与结构特征相比更加重要。本研究提出的融合语义特征和结构特征模型相对于使用语义特征的 BiGRU 模型，在准确率、精确率、召回率、F1 值、平均倒数排名等评价指标均有提升，从而验证了语义特征和结构特征融合方法在提升诊断效果方面的有效性。AFF 模块采用的注意力机制融合策略进一步优化特征融合过程，相较于直接拼接特征的方法展现出更佳表现。

3.3　可解释性

显著性是深度学习模型可解释性的有效标准[27]，显著性的任务是确定哪些症状在诊断过程中起到了关键作用，并按其重要性进行排列，即针对疾病诊断模型的输入 $\boldsymbol{Z}$，对 $\boldsymbol{Z}$ 中每个症状对于诊断结果的影响力进行排序。本文借鉴基于梯度的可解释性方法[28]，对显著性计算公式进行修改。

基于梯度的可解释性方法将模型对应的函数视为非线性函数 $f(\boldsymbol{Z})$，将函数 $f(\boldsymbol{Z})$ 进行一阶泰勒展开，公式为

$$f(\boldsymbol{Z}) \approx \boldsymbol{w}^{\mathrm{T}}\boldsymbol{Z} + \boldsymbol{b} \tag{18}$$

其中

$$\boldsymbol{w} = \frac{\partial f(\boldsymbol{Z})}{\partial \boldsymbol{Z}}\bigg|_{\boldsymbol{Z}} \tag{19}$$

式中　$\boldsymbol{Z}$——输入矩阵

$\boldsymbol{w}$——函数 $f(\boldsymbol{Z})$ 在 $\boldsymbol{Z}$ 处的梯度

$\boldsymbol{b}$——函数 $f(\boldsymbol{Z})$ 在 $\boldsymbol{Z}$ 处的偏置

通过反向传播计算获得梯度 $\boldsymbol{w}$，将 $|\boldsymbol{w}|$ 作为显著性值，$|\boldsymbol{w}|$ 越大，那么 $\boldsymbol{Z}$ 中对应特征对诊断结果的影响也就越大，以判断某一特征对诊断结果的贡献程度。

针对高维向量可视化效果不佳的问题，采用特征缩放方法。假设输入文本包含 N 个症状，缩放后特征向量维度为 M，则显著性矩阵 $\boldsymbol{w} \in \boldsymbol{R}^{M\times N}$ 的计算公式为

$$\boldsymbol{w}_{ij} = \left| \sum_{k=cj}^{c(j+1)} \left[\frac{\partial f(\boldsymbol{Z})}{\partial \boldsymbol{Z}_i} \middle| \boldsymbol{Z}_i \right]_{ik} \right| \tag{20}$$

式中 c——特征缩放倍数

$\boldsymbol{w}_{ij}$——函数 $f(\boldsymbol{Z})$ 对第 i 个症状 $\boldsymbol{Z}_i$ 在第 j 个特征区域的显著性值

在本文模型中，特征向量的维度是 768，将特征缩放倍数 c 设置为 32，每个症状对应的柱状条个数为 24，获得的显著性热图如图 9 所示。该显著性热图细化了特征向量上不同位置的影响程度，横坐标代表特征向量的不同区域，纵坐标代表不同症状，每个柱状条的颜色深浅表示当前特征对预测结果的影响程度，颜色越深，则显著性越高，表明当前特征对模型输出的预测结果有更重要的影响，即该特征对应的症状是模型预测结果的主要原因。

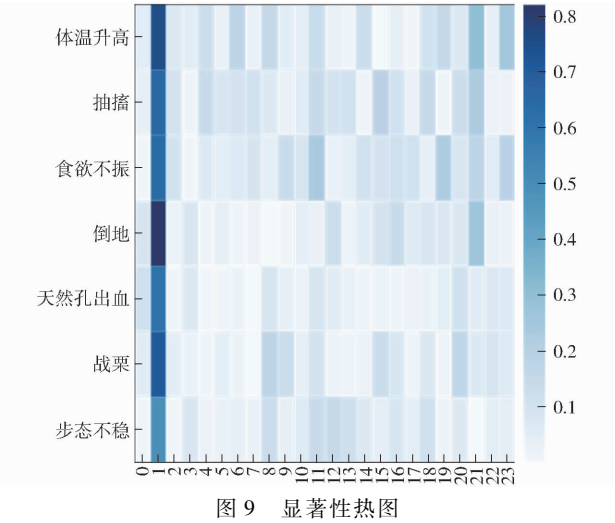


图 9 显著性热图

Fig. 9 Saliency heatmap

为了分析在疾病诊断中的不同症状个数对模型的影响，选择疾病类型为“炭疽”，症状为“体温升高”“抽搐”“食欲不振”“倒地”“天然孔出血”“战栗”“步态不稳”的测试数据，按照症状由少到多的递增顺序，在每个时间步中观察诊断结果。将特征缩放倍数 c 设置为 768，每个症状对应的柱状条个数为 1，获得的显著性热图如图 10 所示，该图验证了每个时间步对应症状的重要程度。在疾病诊断前几个时间步，模型根据当前已有症状，疾病诊断结果

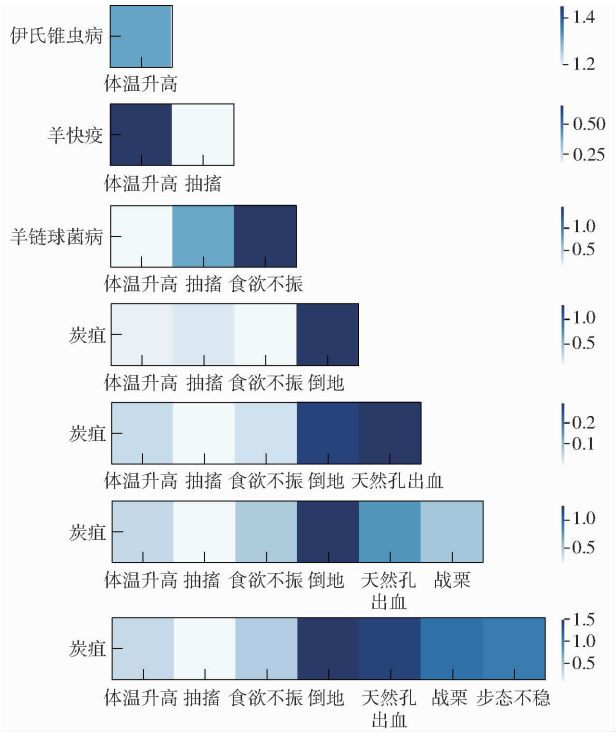


图 10 每个时间步的显著性热图

Fig. 10 Saliency heatmap for each time step

为“伊氏锥虫病”“羊快疫”“羊链球菌病”等错误判断。由于“倒地”症状是炭疽病的重要表现，当模型处理“倒地”症状时，该症状的显著性值较高，表明该症状是炭疽病的关键症状，同时较早症状的影响减弱。在后续时间步中，模型诊断出正确的疾病“炭疽”。

通过显著性计算揭示羊病诊断中的一些规律，对提高诊断的可解释性至关重要。本文选择 12 种常见羊病，通过计算显著性获取这 12 种羊病的典型关键症状，得到的显著性热图如图 11 所示。根据图中深蓝色的区域，可以推断出“炭疽”疾病的关键症状包括“倒地”和“天然孔出血”，次关键症状为“战栗”和“步态不稳”；“羊链球菌病”的关键症状表现为“鼻涕”，次关键症状为“抽搐”；“肝片吸虫病”的关键症状为“腹泻”，次关键症状为“贫血”；“肉毒梭菌中毒症”的关键症状为“点头翘尾”，次关键症状为“流涎”“掉群”和“咀嚼困难”；“羊快疫”的关键症状为“磨牙”和“倒地”；“羊口疮”的关键症状为“流涎”；“大肠杆菌病”的关键症状为“精神沉郁”，次关键症状为“脱水”和“腹泻”；“口蹄疫”的关键症状为“舌糜烂”和“反刍减少”，次关键症状为“跛行”和“食欲不振”；“羊肠毒血症”的关键症状为“昏迷”；“布鲁氏杆菌病”的关键症状为“跛行”，次关键症状为“乳房炎”；“血吸虫病”的关键症状为“精神沉郁”和“腹泻”，次关键症状为“脱毛”和“贫血”；“小反刍兽疫”的关键症状为“腹泻”，次关键症

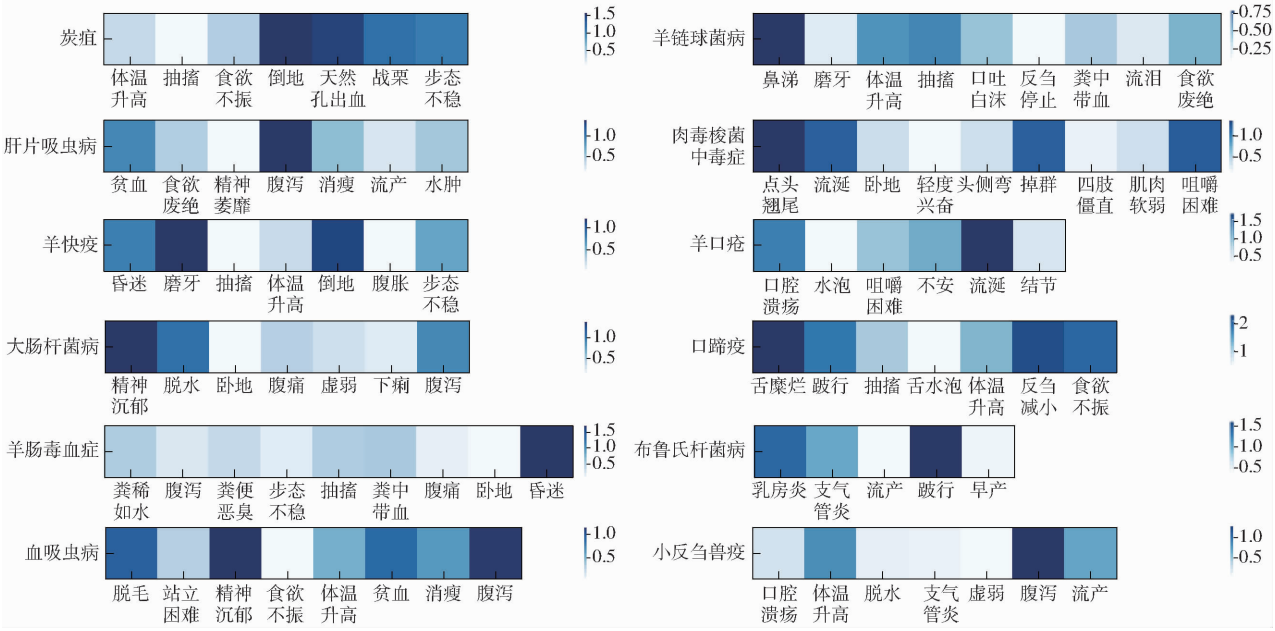


图 11　典型疾病的显著性热图

Fig. 11　Typical disease saliency heatmap

状为“体温升高”和“流产”。

通过直观的可视化方式，辅助兽医和研究人员了解每个症状在诊断过程中影响程度，有助于提高诊断的准确性和可解释性。

4　结论

（1）基于知识图谱和语义与结构融合的羊病诊断方法表现出有效性和鲁棒性。采用 BiGRU 提取症状文本的语义特征信息，采用 GCN 提取知识图谱中潜在的结构特征信息，引入改进的 AFF 模块更好地融合语义特征和结构特征。在羊病症状数据集 Sheep 上准确率、精确率、召回率、F1 值、平均倒数排名分别达到 96.86%、97.73%、97.32%、97.25%、97.49%，在公开数据集 Dxy 和 Muzhi 上准确率、精准率、召回率、F1 值和平均倒数排名均有提高，为其他疾病诊断任务提供参考。

（2）基于梯度的显著性计算改进方法能够有效提高疾病诊断任务的可解释性。根据基于梯度的显著性值计算公式，绘制显著性热图，热图中不同颜色的深浅代表不同症状对预测疾病结果的重要程度，可以更清晰地了解每个症状在诊断过程中的作用，有助于推动疾病诊断任务的可解释性研究。

参　考　文　献

[1] 聂艳召，李书琴. 基于 CBR 的羊病诊断专家系统分析与研究[J]. 农机化研究，2007(7)：33－36.
NIE Yanzhao，LI Shuqin. Research on sheep & goat diagnosis expert system based on CBR[J]. Journal of Agricultural Mechanization Research，2007(7)：33－36.（in Chinese）

[2] 谭文学，席金菊，王京仁. 双推理核山羊疾病诊断专家系统[J]. 农业工程学报，2009，25(增刊 2)：218－222.
TAN Wenxue，XI Jinju，WANG Jingren. Expert system of goat disease diagnosis with dual-reasoning-kernel[J]. Transactions of the CSAE，2009，25(Supp. 2)：218－222.（in Chinese）

[3] 秦宏宇，李建新，高翔，等. 基于模糊规则提升理论的马病辅助诊断专家系统[J]. 农业工程学报，2016，32(5)：194－199.
QIN Hongyu，LI Jianxin，GAO Xiang，et al. Equine diseases auxiliary diagnosis expert system based on fuzzy rule promotion theory[J]. Transactions of the CSAE，2016，32(5)：194－199.（in Chinese）

[4] 张领先，韩梦瑶，丁俊琦，等. 作物病害智能诊断与处方推荐技术研究进展[J]. 农业机械学报，2023，54(6)：1－18.
ZHANG Lingxian，HAN Mengyao，DING Junqi，et al. Research progress in intelligent diagnosis and prescription recommendation of crop diseases[J]. Transactions of the Chinese Society for Agricultural Machinery，2023，54(6)：1－18.（in Chinese）

[5] 胡满满，陈旭，孙毓忠，等. 基于动态采样和迁移学习的疾病预测模型[J]. 计算机学报，2019，42(10)：2339－2354.
HU Manman，CHEN Xu，SUN Yuzhong，et al. A disease prediction model based on dynamic sampling and transfer learning[J]. Chinese Journal of Computers，2019，42(10)：2339－2354.（in Chinese）

[6] MEN L，ILK N，TANG X，et al. Multi-disease prediction using LSTM recurrent neural networks[J]. Expert Systems with Applications，2021，177：114905.

[7] 徐畅，丁俊琦，赵聃桐，等. 基于 LightGBM 和处方数据的番茄病害诊断方法[J]. 农业机械学报，2022，53(9)：286－294.

XU Chang, DING Junqi, ZHAO Dantong, et al. Tomato disease diagnosis method based on LightGBM and prescription data [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(9): 286 – 294. (in Chinese)

[8] 丁俊琦, 李博, 乔岩, 等. 基于植物电子病历多类型数据融合的作物病害诊断方法[J]. 农业机械学报, 2023, 54(1): 196 – 204,223.
DING Junqi, LI Bo, QIAO Yan, et al. Crop disease diagnosis method based on fusion of multiple types of data from plant EMRs [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(1): 196 – 204,223. (in Chinese)

[9] 董丽丽, 程炯, 张翔,等. 融合知识图谱与深度学习的疾病诊断方法研究[J]. 计算机科学与探索, 2020, 14(5): 815 – 824.
DONG Lili, CHENG Jiong, ZHANG Xiang, et al. Research on disease diagnosis method combining knowledge graph and deep learning[J]. Journal of Frontiers of Computer Science and Technology, 2020, 14(5): 815 – 824. (in Chinese)

[10] 翟增林, 王天一. 融合知识图谱与深度学习的羊病诊断方法[J]. 计算机与数字工程, 2022, 50(12): 2831 – 2836.
ZHAI Zenglin, WANG Tianyi. Diagnosis method of sheep disease based on knowledge graph and deep learning[J]. Computer & Digital Engineering, 2022, 50(12): 2831 – 2836. (in Chinese)

[11] WANG H, SHEN W, ZHANG Y, et al. Diagnosis of dairy cow diseases by knowledge-driven deep learning based on the text reports of illness state[J]. Computers and Electronics in Agriculture, 2023, 205:107564.

[12] KIPF T, WELLING M. Semi-supervised classification with graph convolutional networks[C]// International Conference on Learning Representations (ICLR), 2017: 1 – 14.

[13] DAI Y, GIESEKE F, OEHMCKE S, et al. Attentional feature fusion[C]//2021 IEEE Winter Conference on Applications of Computer Vision (WACV), 2021: 3559 – 3568.

[14] 昝红英, 韩杨超, 范亚鑫, 等. 中文症状知识库的建立与分析[J]. 中文信息学报, 2020, 34(4): 30 – 37.
ZAN Hongying, HAN Yangchao, FAN Yaxin, et al. Construction and analysis of symptom knowledge base in Chinese[J]. Journal of Chinese Information Processing, 2020, 34(4): 30 – 37. (in Chinese)

[15] XU L, ZHOU Q, GONG K, et al. End-to-end knowledge-routed relational dialogue system for automatic diagnosis[C]// Proceedings of the Thirty-Third AAAI Conference on Artificial Intelligence and Thirty-First Innovative Applications of Artificial Intelligence Conference and Ninth AAAI Symposium on Educational Advances in Artificial Intelligence (AAAI'19/IAAI'19/EAAI'19), 2019: 7346 – 7353.

[16] WEI Z, LIU Q, PENG B, et al. Task-oriented dialogue system for automatic diagnosis[C]// Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (ACL), 2018: 201 – 207.

[17] KIM Y. Convolutional neural networks for sentence classification[C]// Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP), 2014: 1746 – 1751.

[18] LAI S, XU L, LIU K, et al. Recurrent convolutional neural networks for text classification[C]// Proceedings of the Twenty-Ninth AAAI Conference on Artificial Intelligence (AAAI), 2015: 2267 – 2273.

[19] LIU P, QIU X, HUANG X. Recurrent neural network for text classification with multi-task learning[C]// Proceedings of the Twenty-Fifth International Joint Conference on Artificial Intelligence (IJCAI), 2016: 2873 – 2879.

[20] JOHNSON R, ZHANG T. Deep pyramid convolutional neural networks for text categorization[C]// Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (ACL), 2017: 562 – 570.

[21] 肖琳, 陈博理, 黄鑫, 等. 基于标签语义注意力的多标签文本分类[J]. 软件学报, 2020, 31(4): 1079 – 1089.
XIAO Lin, CHEN Boli, HUANG Xin, et al. Multi-label text classification method based on label semantic information[J]. Journal of Software, 2020, 31(4): 1079 – 1089. (in Chinese)

[22] CHENG Y, ZOU H, SUN H, et al. HSAN-capsule: a novel text classification model[J]. Neurocomputing, 2022, 489: 521 – 533.

[23] LU G, LIU Y, WANG J, et al. CNN – BiLSTM – Attention: a multi-label neural classifier for short texts with a small set of labels[J]. Information Processing & Management, 2023, 60(3): 103320.

[24] MIKOLOV T, CHEN K, CORRADO G, et al. Efficient estimation of word representations in vector space[C]// International Conference on Learning Representation (ICLR), 2013: 1 – 12.

[25] DEVLIN J, CHANG M, LEE K, et al. BERT: pre-training of deep bidirectional transformers for language understanding[C]// Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics (ACL), 2019: 4171 – 4186.

[26] MAATEN L, HINTON G. Visualizing data using t-SNE[J]. Journal of Machine Learning Research, 2008, 9: 2579 – 2605.

[27] WIEGREFFE S, PINTER Y. Attention is not not explanation[C]// Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP – IJCNLP), 2019: 11 – 20.

[28] LI J, CHEN X, HOVY E, et al. Visualizing and understanding neural models in NLP[C]// Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (ACL), 2016: 681 – 691.