

doi:10.6041/j.issn.1000-1298.2024.12.032

融合动态词典特征和 CBAM 的苹果病虫害命名实体识别方法

蒲 攀^{1,2} 刘 勇¹ 张 越¹ 王飞逸¹ 苗园爽¹ 谦 博¹ 黄铝文^{1,3}

(1. 西北农林科技大学信息工程学院, 陕西杨凌 712100; 2. 农业农村部农业物联网重点实验室, 陕西杨凌 712100;

3. 陕西省农业信息智能感知与分析工程技术研究中心, 陕西杨凌 712100)

摘要: 在苹果病虫害命名实体识别中, 针对罕见字语义特征提取不充分, 实体类别相似难以区分的问题, 本文提出一种融合动态词典和卷积块注意力模块(Convolutional block attention module, CBAM)的实体识别方法。首先, 基于字的双向长短时记忆-条件随机场模型(Bidirectional long short-term memory - conditional random field, BiLSTM - CRF), 在嵌入层利用通道注意力网络(Channel attention module, CAM)动态融合词典信息, 同步集成字的四角号码信息, 以提高对罕见字表征能力。随后, 对序列编码层输出序列特征, 基于空间注意力网络(Spatial attention module, SAM), 新增并行连接的空间注意力(Parallel connection spatial attention, PCSA)模块, 提高模型对上下文信息提取能力。最后, 使用含有6大类标签、127 574个标注字符的苹果病虫害数据集进行验证测试。结果显示模型精确率、召回率和F1值分别达到95.76%、92.46%、94.08%, 较现有的常用同类模型性能显著提升, 实现了对农业病虫害命名实体的精准识别。

关键词: 苹果病虫害; 命名实体识别; 动态嵌入; 词典; CBAM

中图分类号: TP391.1 文献标识码: A 文章编号: 1000-1298(2024)12-0333-11

OSID: 

Named Entity Recognition of Apple Diseases and Pests Based on Dynamic Dictionary Features and CBAM

PU Pan^{1,2} LIU Yong¹ ZHANG Yue¹ WANG Feiyi¹ MIAO Yuanshuang¹ QIAN Bo¹ HUANG Lüwen^{1,3}

(1. College of Information Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China

2. Key Laboratory of Agricultural Internet of Things, Ministry of Agriculture and Rural Affairs, Yangling, Shaanxi 712100, China

3. Shaanxi Engineering Research Center for Intelligent Perception and Analysis of Agricultural Information, Yangling, Shaanxi 712100, China)

Abstract: In the named entity recognition of apple diseases and pests, a entity recognition model was proposed to address the problems of insufficient semantic feature extraction for rare words and difficulties in distinguishing entities due to similar entity categories. This model integrated dynamic lexicon and convolutional block attention module (CBAM). Firstly, based on the bidirectional long short-term memory - conditional random field model (BiLSTM - CRF), a channel attention module (CAM) was used to dynamically obtain lexicon information for the words, and the four-corner code information of Chinese characters was simultaneously fused to enhance the representation ability for rare words. Then after the sequence features output by the sequence encoding layer, a parallel connection spatial attention (PCSA) module based on the spatial attention module (SAM) was added to improve the model's ability to extract contextual information. Finally, the model was validated and tested by using an apple disease and pest dataset which contained six major classes and 127 574 annotated characters. The results showed that the precision, recall, and F1 value could reach 95.76%, 92.46% and 94.08%, respectively, indicating a significant improvement in performance compared with existing commonly used similar models, which achieved accurate recognition of agricultural disease and pest named entities.

Key words: apple diseases and pests; named entity recognition; dynamic embedding; lexicon; CBAM

收稿日期: 2024-01-20 修回日期: 2024-06-04

基金项目: 陕西省重点研发计划项目(2023-YBNY-219)

作者简介: 蒲攀(1982—), 男, 副教授, 博士, 主要从事农业物联网与传感器网络研究, E-mail: pupan@nwsuaf.edu.cn

通信作者: 黄铝文(1976—), 男, 副教授, 博士生导师, 主要从事生物图像处理与机器人控制技术研究, E-mail: huanglwwen@nwsuaf.edu.cn

0 引言

中国是世界上最大的苹果生产国,苹果种植面积和产量均超过世界总量的 50%^[1],但因病虫害,每年都遭受重大经济损失。当前,基于知识图谱构建智能问答系统,精准指导种植户解决生产问题,是实现病虫害高效防治、降低经济损失的重要手段。在苹果病虫害领域知识图谱的构建中,领域命名实体识别(Domain named entity recognition, DNER)^[2]是关键,其性能直接影响知识图谱的构建质量^[3],因此成为苹果病虫害智能问答系统研究热点。

近年来,基于深度学习的实体自动识别方法在医学^[4-6]、农业^[7-9]、牧业^[10]和营养健康^[11]等领域广泛应用。AN 等^[4]将字嵌入和字的标签嵌入相结合,提出了基于多头注意力机制的中文临床实体识别模型;杨璐等^[10]将 BiLSTM 输出作为主分类层,Bert 输出作为辅助分类,通过注意力机制组合完成兽药实体识别;郑丽敏等^[11]使用 BERT 进行字符信息和词汇信息嵌入,并结合位置和词汇边界信息进行编码,最后通过规则对预测的营养健康实体结果进行修正;蒲攀等^[12]优化 Transformer 模型并基于平均融合法集合 BiLSTM 特征,提高苹果生产领域实体识别的准确性。

虽然“字”性能优于“词”^[13],但由于完全基于字符 DNER 不能充分利用词信息,需要多粒度的词信息以提高模型性能。为此,ZHANG 等^[14]将潜在的词信息融合 Lattice LSTM 模型,消除了分词错误和缓解上下文歧义。然而,由于每个字符存在不确定的候选字集,进而影响 Lattice LSTM 模型的训练和推理速度。为此,LIU 等^[15]提出 WC-LSTM 模型,将字信息编码成固定向量并分配给单个字符,以适应批次训练和不同使用场景。MA 等^[16]利用 SoftLexicon 将匹配词分成 4 类词集,通过引入静态词频加权策略将词信息整合到字信息中,但仍然存在着词集之间的重要程度和 4 种词集位置关系未能得到充分利用的问题。ZHANG 等^[17]把词典和字符的相似词引入 BiLSTM-CRF 模型,增强潜在语义信息以提高模型识别率,而 GUO 等^[7-8]将字的部首信息和字形特征加以利用,实现多粒度提高语义表征能力。此外,对于 DNER 模型的序列编码层,多使用 BiLSTM 作为主流的深度学习网络模型^[18]。虽然能较好地捕捉上下文特征和序列信息,但是随着句长增加,BiLSTM 存在提取特征能力下降的不足^[6]。同时该模型会因每个字符对命名实体识别任务的贡献相同,缺乏对重要关键字的关注,从而导致对苹果领域特征提取不充分。

针对上述实体识别模型的不足,聚焦苹果病虫害相关实体的罕见字语义特征提取困难和实体类别间的相似性导致难以区分的问题,本研究结合苹果病虫害语料特点,在嵌入层中使用通道注意力网络动态融合 SoftLexicon 模型中的 4 类词汇信息,以区分外部词的重要程度,同时结合字的四角号码信息,学习汉字基本结构知识以增强汉字的表征能力。最后提出基于空间注意力的 PCSA 模块来弥补 BiLSTM 模型在特征提取方面的不足,以期整体提升苹果病虫害实体识别的精确度。

1 数据集构建

1.1 语料来源

在西北农林科技大学苹果试验示范站(陕西省渭南市白水县,35°10'37.56"N,109°35'27.67"E)农技人员指导下,使用已经科技推广使用多年的《白水苹果规范化栽培技术手册》、《瑞阳瑞雪高效生产技术》作为基础语料。另外,使用爬虫获取中国农化招商网站(<http://www.1988.tv/bch/list-22.html>)部分数据信息,补充构建了苹果病虫害相关语料库,以提高苹果病虫害数据专业度和丰富性,数据来源信息如表 1 所示。参照园艺与植保领域专家建议,将苹果病虫害领域实体分为苹果病害、虫害、病害病原等 6 大类,如表 2 所示。

表 1 语料来源详细信息

Tab. 1 Details of corpus sources

名称	来源	字数/字
《白水苹果规范化栽培技术手册》	西北农林科技大学 苹果试验示范站	2.0 × 10 ⁴
《瑞阳瑞雪高效生产技术》	西北农林科技大学 苹果试验示范站	5.4 × 10 ⁴
中国苹果病害病原菌物名录	《菌物学报》	1.8 × 10 ⁴
苹果病虫害知识语料	中国农化招商网站	1.1 × 10 ⁵

表 2 领域实体类别

Tab. 2 Domain entity categories

实体种类	实体定义	实体描述	示例
苹果病害	dis	苹果相关病害	苹果腐烂病
苹果虫害	pest	苹果相关虫害	苹果梨小食心虫
病虫害别名	name	苹果病害或虫害的别名	大斑病、大星病、褐星病
为害部位	par	苹果病害或虫害为害的部位	花、叶、根
防治药剂	pesticide	防治苹果病害和虫害的药剂	40% 五氯硝基苯、25% 乳油、30% 恶霉灵
病害病原	cau	苹果病害的病原	黑腐皮壳菌、土壤习居菌

1.2 语料预处理

由于基础语料中存在一部分与病虫害无关的知识,需要对文本信息进行预处理。处理过程包括:①对语料中的重复内容、描述偏离苹果病虫害主体的相关文本进行删减。②对文本数据进行去空格、空行、乱码字符操作。③文本格式转换,使每一个字符单独占据一行。经过上述数据预处理过程,本文构建完成包含 127 574 个中文字符的原始语料数据集。

对原始语料数据采用 BIOES 方式进行标注。数据标注示例如图 1 所示。例如苹果病害类实体“苹果霉心病”中 5 个字符的标签分别为“B - DIS”、“I - DIS”、“I - DIS”和“E - DIS”,图中其他类别的实体标注也均符合 BIOES 规则。将试验数据集按 8:1:1 的比例划分为训练集、验证集和测试集,其 6 类实体数量的划分结果如表 3 所示。



图 1 数据标注实例

Fig. 1 Example of data annotation

表 3 数据集划分

Tab. 3 Data set partition

类别	苹果 病害数	苹果 虫害数	病虫害 别名数	为害 部位数	防治 药剂数	病害 病原数
训练集	609	350	106	809	1 043	155
验证集	81	42	14	132	116	119
测试集	84	48	13	136	150	21

与其他领域数据相比,苹果病虫害数据集还具有以下显著特点:①实体词多包含罕见字,导致其特征提取不充分。如防治药剂中“烯肟菌胺·苯醚甲环唑·噻虫嗪种衣剂”的实体和病害病原中“河口械胶锈菌”的实体。这些实体特点常会导致通用命名实体识别模型的准确率降低。②实体类别间的相似性,病虫害别名实体和病虫害实体在语义和形式上相似。如文本“苹果轮纹病,又称苹果粗皮病”,单独识别“苹果轮纹病”和“苹果粗皮病”哪个是别名实体存在困难。③苹果病虫害语料专业性强,常用的分词工具处理易产生分词错误,如防治药剂“嘧啶核苷类水剂”、病原“细极链孢子”等实体,这些数据特点容易造成当前常用模型在对苹果病虫害数据集识别时准确率下降。

1.3 数据增强处理

由于罕见字容易在病害病原类实体中出现,且该类实体数量偏少,为此对其进行局部的数据增强。

首先筛选出包含病害病原的句子,并存储在 TXT 文件中;然后在收集的苹果病虫害语料上,使用 Word2Vec 模型训练出词向量并将其存储;最后对 TXT 文件每一句话中的词语进行近义词替换。在此过程中,随机选择 30% 的 token,对选中的 token 寻找 Word2Vec 词表中余弦距离最近的词替换。最终将病害病原的实体总个数扩充至 510 个。

2 苹果病虫害命名实体识别模型建立

针对苹果病虫害语料的特点和常用模型存在的问题,本文构建的模型整体框架如图 2 所示。根据苹果病虫害语料专业性强的特点,模型采用基于字符嵌入的思路,避免因分词操作处理可能带来的错误。模型由嵌入层、BiLSTM^[19]序列编码层、PCSA 层、CRF^[20]层组成。嵌入层将动态词典信息和字形信息融合到字符嵌入过程中,充分提取罕见字的语义,以期解决苹果病虫害领域实体多罕见字问题;序列编码层用于学习文本的序列特征;PCSA 层使用基于通道注意力的网络来处理两个不同角度的语义信息,实现对文本重要位置信息的关注,以解决病虫害实体类别不易区分的问题;CRF 层用于约束标签序列并获得一个全局最优的标注序列。

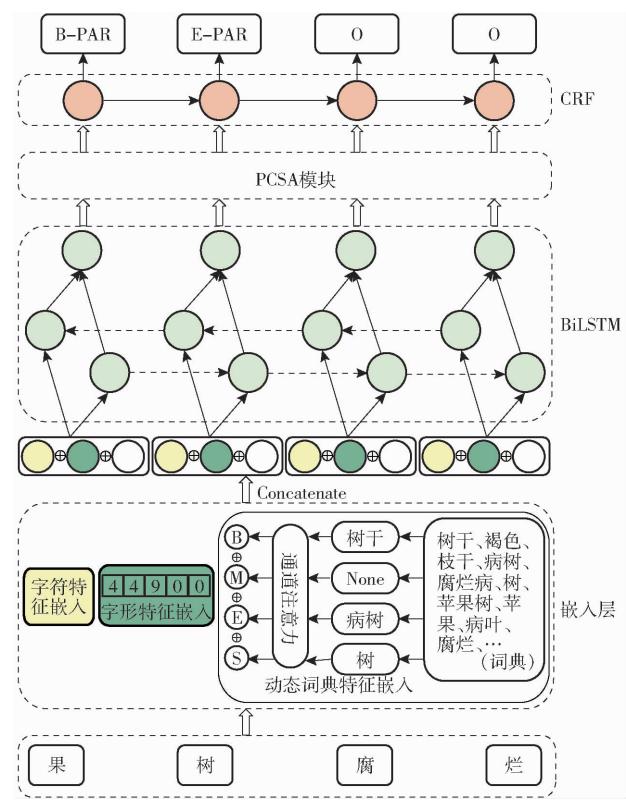


图 2 模型整体框架图

Fig. 2 Overall architecture of proposed model

2.1 嵌入层

2.1.1 字符嵌入

文本字符不能直接使用,需要转换成分布式向

量表示才能被计算机接收并计算。常用模型的嵌入层多针对通用数据领域,运用预训练语言模型BERT^[21]得到字的特征向量。然而,以这种方式得到的特征向量一般性突出,在一定程度上会削弱甚至丢掉苹果病虫害等专业领域的特征信息^[22]。针对以上问题,本文使用Word2Vec^[23]工具对收集的苹果语料库进行训练,生成字向量。因为Skip-Gram模型能更频繁训练罕见字的向量表示,泛化能力优于CBOW模型^[24],故在训练过程中选择使用Skip-Gram模型。在一个给定长度为n的序列 $X=\{C_1, C_2, \dots, C_n\}$ 上,从嵌入矩阵中查找到嵌入向量,用 $E=(e_1, e_2, \dots, e_i, \dots, e_n)$ 表示。其中*i*($1 \leq i \leq n$)表示序列中第*i*个字符,第*i*个字符嵌入为 $e_i \in \mathbf{R}^d$,*d*为词向量维度。

2.1.2 基于动态嵌入的词典

为减少病害病原和药剂等实体中的罕见字对病虫害实体标注的影响,受到SoftLexicon模型的启发^[16],利用词典信息充分提取罕见字的语义信息和潜在的词汇信息。在SoftLexicon模型中,它将匹配词按照不同位置分为4类,对于序列 $S=\{C_0, C_1, \dots, C_n\}$,根据字典从句子中提取到每个字符 C_t ($t=0, 1, \dots, n$)的匹配词 W_{ij} 。 W_{ij} 表示为序列的子序列 $\{C_i, C_{i+1}, \dots, C_j\}$ ($0 \leq i < t \leq j \leq n$)。在匹配词组之后,根据字符 C_t 在 w_{ij} 中的位置,将这些词分为4类 $\{B, I, E, S\}$ 。这4个类别的定义分别为

$$\begin{cases} B(C_t) = \{w_{ij} | 0 \leq i < t < j \leq n\} \\ I(C_t) = \{w_{ij} | 0 \leq i < t < j \leq n\} \\ E(C_t) = \{w_{ij} | 0 \leq i < t \leq n\} \\ S(C_t) = \{w_{ij} | 0 \leq i = j \leq n\} \end{cases} \quad (1)$$

$B(C_t)$ 、 $I(C_t)$ 、 $E(C_t)$ 、 $S(C_t)$ 表示字符 C_t 处于开始位置、中间位置、结尾位置、单个字符的词集。

词组匹配示例如图3所示,字符“果”经过词典匹配后的子序列有{果树,苹果树,苹果,果},按公式(1)划分成4类。同理,字符“斑”的子序列有{斑病,大斑,斑}。若其中某个类别的集合为空,则填充“None”,如字符“斑”子序列的集合 $I(C_t)$ 为“None”。

MA等^[16]在SoftLexicon模型中使用4类词集的词频作为静态权重,进行静态嵌入。但由于每个词都会存在不同的语义特征,重要性也不相同,这将导致含有罕见字的实体只能识别出正确实体的一部分,进而模型可能出现精确率较高但召回率变差的现象(如3.3.3节试验结果)。而使用普通的注意力机制处理输入的词典特征向量,由于它关注输入序列的整体,只能突出某些部分数据重要,并不能更

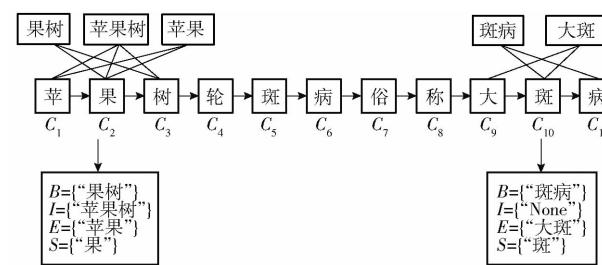


图3 词组匹配示例

Fig. 3 Example of phrase matching

细致地区分4类词集的重要程度。

因此,在词典融合过程中引入CAM模型生成动态词典特征信息。本文将4类词集视作4个通道,通过使用CAM调整每个通道的权重,允许模型更有效地融合和利用不同通道的信息,同时通道间的交互有助于模型更好地理解输入数据。其具体做法是:先将4个词集扩展为一个高维矩阵作为输入,分别进行全局平均池化和最大池化操作;然后经过多层的感知机和ReLU激活函数;最后将输出的通道权重乘以输入的特征图,便得到动态词向量特征矩阵。动态词典特征产生过程如图4所示,其中AvgPool用来统计全局编码信息的特征,MaxPool用来提供最突出的编码特征。由于两个经过平均池化和最大池化处理的特征位于同一语义嵌入空间,因此本文采用共享的2层感知机进行推理。通道注意力机制计算公式为

$$\mathbf{x}_i = r(\mathbf{x}_{i1}, \mathbf{x}_{i2}, \mathbf{x}_{i3}, \mathbf{x}_{i4}) \quad (2)$$

$$\mathbf{M}_c(\mathbf{x}_i) = \delta(w_1 w_0 (\text{AvgPool}(\mathbf{x}_i) + \text{MaxPool}(\mathbf{x}_i))) \quad (3)$$

$$\mathbf{x}_i = \mathbf{M}_c(\mathbf{x}_i) \mathbf{x}_i \quad (4)$$

式中 $r(\cdot)$ ——reshape 函数

$\mathbf{x}_{i1}, \mathbf{x}_{i2}, \mathbf{x}_{i3}, \mathbf{x}_{i4}$ ——4个词集的词向量

\mathbf{x}_i ——拼接后词向量

$\mathbf{M}_c(\mathbf{x}_i)$ ——词典权重系数矩阵

w_1, w_0 ——可学习参数

$\delta(\cdot)$ ——ReLU 函数

2.1.3 字形嵌入

通过对苹果病虫害语料的分析发现,同类实体在字形方面有许多相似之处。如表4示例,对于包含汉字结构“酉”的字符,多数含义表示为药剂,在防治药剂实体中常出现类似的字形结构,如“醚”、“酮”、“酯”等,其他实体的汉字结构也有类似特点。因为汉字属于象形文字,大部分仍保留着其原意。

为充分利用字符的字形关键信息,采用汉字的四角号码(汉语词典常用检字方法之一,按照字的结构对汉字进行编码并归类^[25])信息来增强字符语

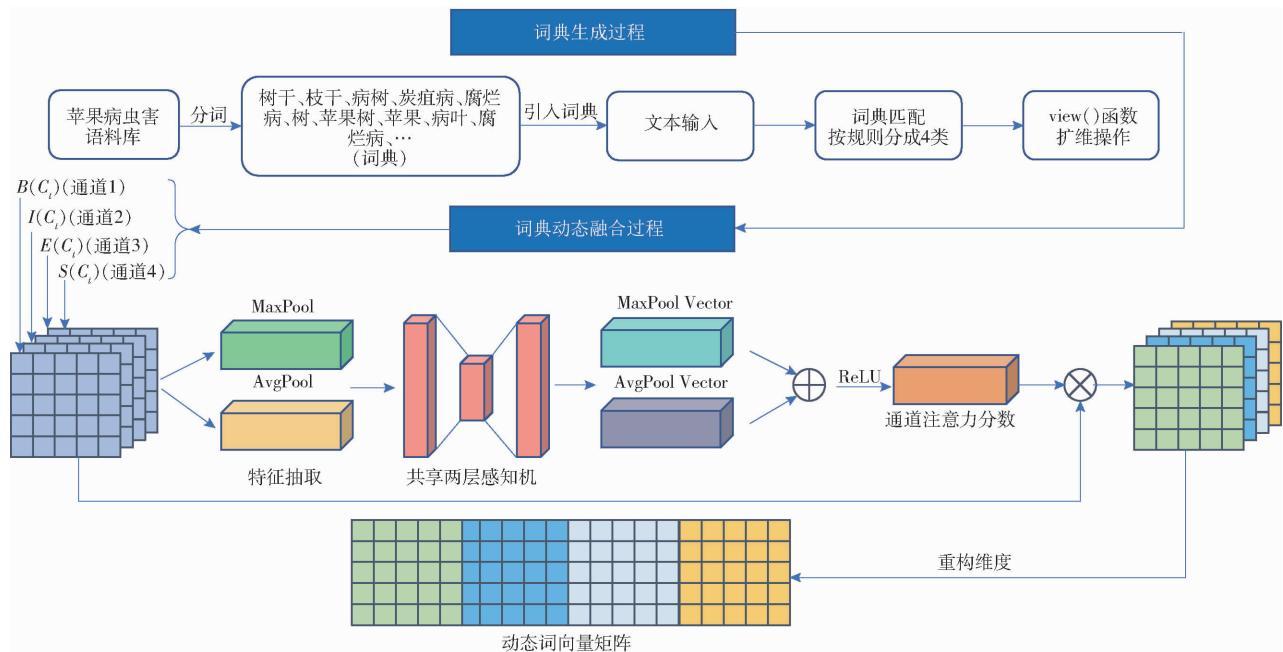


图 4 词典生成及特征动态融合过程示意图

Fig. 4 Schematic of dictionary generation and feature dynamic fusion process

表 4 汉字结构及示例

Tab. 4 Chinese character structure and examples

汉字结构	含义	汉字示例(四角号码)
木	部位	根(47932)、枝(44947)、梢(49927)、树(44900)
犮	病害	病(00127)、痘(00118)、疫(00147)、疽(00112)
虫	虫害	蛾(53150)、蝉(58156)、蟠(54127)、蝇(56116)、蝽(5516)
酉	化学药剂	酯(12661)、酮(17620)、醚(19369)

义信息。即便他们没有在训练集中出现,也能使用这些信息特征加强在测试集中出现的字符语义信息提取,进而改善因苹果病虫害数据集实体词多包含罕见字所导致的罕见实体识别困难问题。在获得字符的四角号码信息后,为加速模型快速收敛,对特征进行归一化处理,得到字符字形特征向量,公式为

$$f_i = \varphi(F(C_i)) \quad (5)$$

式中 $F(\cdot)$ ——四角号码转换函数

$\varphi(\cdot)$ ——归一化函数

最后,将动态嵌入的词集重构为高维矩阵之前的维度,对外部词汇信息特征向量、字符的字形特征向量以及字向量进行拼接,送入到序列编码层中。字符最终加强表示为

$$[\mathbf{x}_{i1} \ \mathbf{x}_{i2} \ \mathbf{x}_{i3} \ \mathbf{x}_{i4}] = \text{view}(\mathbf{x}_i) \quad (6)$$

$$\mathbf{g}_i = (\mathbf{e}_i, f_i, \mathbf{x}_{i1}, \mathbf{x}_{i2}, \mathbf{x}_{i3}, \mathbf{x}_{i4}) \quad (7)$$

式中 $\text{view}(\cdot)$ ——重构张量维度

\mathbf{g}_i ——特征融合后向量

2.2 BiLSTM 编码层

BiLSTM 模块从字符的嵌入层接收输入向量矩阵 E ,进一步获取文本的序列信息和学习文本的上

下文特征。在研究中选择 BiLSTM, 主要因为要同时考虑句子中每个字符的上下文信息,并可以将它们结合起来以获得更全面的表示。同时,输入门和遗忘门共同控制单元状态更新,避免产生长期依赖性问题。LSTM 主要包含输入门 i_t 、遗忘门 f_t 、细胞状态 S_t 和输出门 O_t 共 4 部分^[26]。计算过程为

$$i_t = \text{Sigmoid}(\mathbf{w}_i [\mathbf{h}_{t-1}, \mathbf{g}_i] + \mathbf{b}_i) \quad (8)$$

$$f_t = \text{Sigmoid}(\mathbf{w}_f [\mathbf{h}_{t-1}, \mathbf{g}_i] + \mathbf{b}_f) \quad (9)$$

$$\tilde{S}_t = \tanh(\mathbf{w}_e [\mathbf{h}_{t-1}, \mathbf{g}_i] + \mathbf{b}_e) \quad (10)$$

$$S_t = f_t \otimes \tilde{S}_t + i_t \otimes \tilde{S}_t \quad (11)$$

$$O_t = \text{Sigmoid}(\mathbf{w}_o [\mathbf{h}_{t-1}, \mathbf{g}_i] + \mathbf{b}_o) \quad (12)$$

$$h_t = O_t \otimes \tanh(S_t) \quad (13)$$

式中 $\mathbf{w}_i, \mathbf{w}_f, \mathbf{w}_e, \mathbf{w}_o$ ——权重矩阵

$\mathbf{b}_i, \mathbf{b}_f, \mathbf{b}_e, \mathbf{b}_o$ ——运算偏置

$\mathbf{h}_{t-1}, \mathbf{h}_t$ —— $t-1$ 和 t 时刻输出特征向量

2.3 PCSA 层

由于句长增加,BiLSTM 模型特征提取能力将会下降。同时本研究在试验过程中发现经典模型虽能正确标注实体边界,但由于在苹果病虫害数据集中存在实体类别间的相似性现象(如病害实体和别名实体),导致对病虫害实体类别分辨错误。

为解决此问题,本文提出一个并行连接的空间注意模块。该模块对 BiLSTM 模型输出进行处理,以实现对 BiLSTM 模型的输出再进行重要词信息特征的进一步捕捉,改善对重要位置字词关注不足的问题。使用到的空间注意力模块是一种在图像特征提取过程中发现更重要位置像素特征的机制^[27],将

这一思想运用到文本,以提取文本重要位置的特征。PCSA 总体结构如图 5 所示,文本特征经过 BiLSTM 层后,得到特征图 $h \in \mathbf{R}^{W \times C}$,其中 W 为句子的长度, C 为 BiLSTM 的隐藏层维度。在本研究中,文本被当做通道数为 C 、尺寸为 $W \times 1$ 的图像,特征图 h 中的每一个像素表示文本的一个字符。为获取到更丰富的语义信息,PCSA 使用了两个不同的卷积层 M_1 和 M_2 ,并分别通过 SAM 模块实现最后拼接。其计算过程为

$$\begin{cases} F_1 = \text{Conv}^{1 \times 3}(\text{Unsqueeze}(h)) \\ F_2 = \text{Conv}^{1 \times 5}(\text{Unsqueeze}(h)) \end{cases} \quad (14)$$

$$\begin{cases} M_s(F_1) = \text{Sigmoid}(\text{Conv}^{7 \times 7}([\text{AvgPool}(F_1); \text{MaxPool}(F_1)])) \\ M_s(F_2) = \text{Sigmoid}(\text{Conv}^{7 \times 7}([\text{AvgPool}(F_2); \text{MaxPool}(F_2)])) \end{cases} \quad (15)$$

$$E = [M_s(F_1) \times F_1; M_s(F_2) \times F_2] \quad (16)$$

式中 $\text{Conv}^{1 \times 3}, \text{Conv}^{1 \times 5}, \text{Conv}^{7 \times 7} — 1 \times 3, 1 \times 5, 7 \times 7$ 卷积核

$\text{Unsqueeze}(\cdot)$ ——扩维函数

其中式(15)为空间注意力计算。

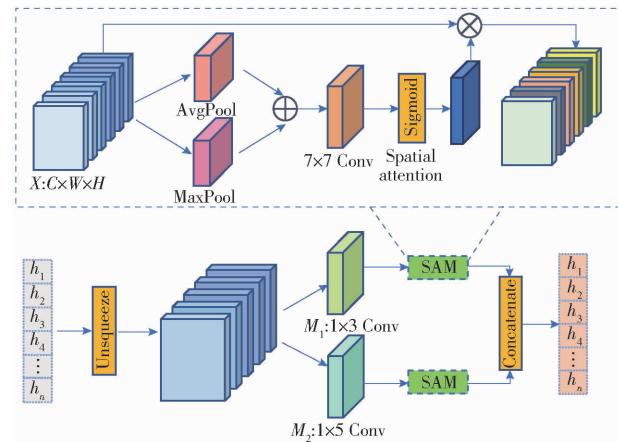


图 5 PCSA 结构图

Fig. 5 Architecture of PCSA

2.4 CRF 层

对于 DNER 任务,输出的标签之间存在较强的依赖关系。例如在标签 BIOES 中,标记“I”不可能出现在标记“B”之前。因此,使用 CRF 来联合建模标签序列,并使用 Viterbi 算法搜索输出的标签序列,将具有预测最高总得分的序列作为模型输出。对于输入句子 X 来说,输出标签序列 $y = \{y_1, y_2, \dots, y_n\}$ 的得分公式为

$$\text{score}(X, y) = \sum_{i=0}^n A_{y_i, y_{i+1}} + \sum_{i=0}^n N_{i, y_i} \quad (17)$$

式中 $A_{y_i, y_{i+1}}$ ——标签转移概率

N_{i, y_i} ——第 i 个字是 y_i 的标签

$\text{score}(X, y)$ ——输出序列得分

3 试验

3.1 试验环境与参数设置

试验在搭载 NVIDIA GeForce RTX 3080Ti 显卡的高性能服务器上进行,操作系统版本为 Ubuntu 18.04,CUDA 版本为 10.1.24,编程语言为 Python 3.7,采用 PyTorch 1.7.1 深度学习框架完成模型构建和训练评估。

模型其他关键参数设置如下:批次大小为 16,隐藏层大小为 256,训练周期为 50。为优化提升模型性能,通过单因素试验分析了学习率和随机失活率对模型性能的影响,以确定其最佳取值。图 6 为学习率改变对模型的影响,当学习率为 0.002 时 F1 值最高。图 7 为不同随机失活率的试验结果,当随机失活率为 0.5 时 F1 值最高。保持试验环境相同,以测试集数据为评估对象。模型定量评价参数选取准确率(Accuracy)、精确率(Precision, P)、召回率(Recall, R)和 F1 值^[28]。

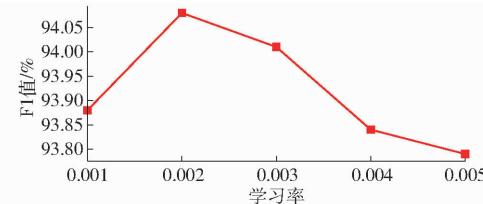


图 6 不同学习率的模型性能曲线

Fig. 6 Model performance results at different learning rates

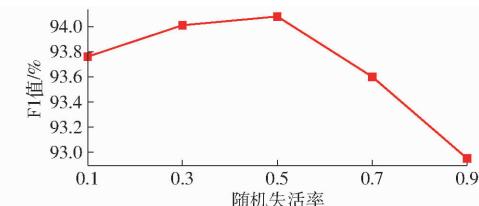


图 7 不同随机失活率的模型性能曲线

Fig. 7 Model performance results at different dropout rates

3.2 数据增强质量测评

为评测利用近义词替换的数据增强方法对模型性能的影响,将本模型分别放在增强前、后的数据集上进行训练,最后在测试集上进行验证,得到如图 8 所示的准确率对比曲线。

从图 8 可以看出,将病害病原相关的句子进行数据增强并没有提升模型整体性能,反而准确率下降。通过查看增强后的数据集,发现尽管挑选出了最相似的近义词进行替换,但是替换后的语句上下文语义发生改变,不符合正常的书写表达。同时也出现将病害病原实体中的词语替换掉,导致出现错误实体的现象。例如,将“胶孢炭疽菌”实体,换成了错误实体“苦腐病炭疽菌”。综上基于近义词替

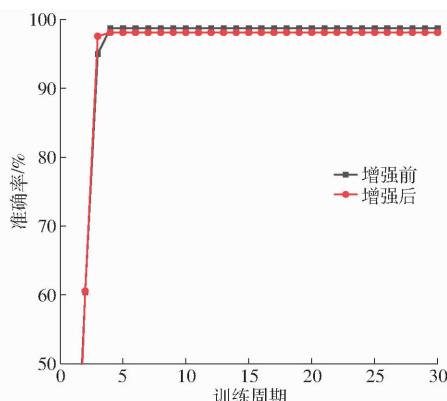


图 8 准确率对比曲线

Fig. 8 Comparison curves of accuracy

换方法增强后的数据集会带来新的噪声, 影响模型训练的质量, 故本文使用未增强的数据集来完成模型训练。

3.3 试验结果分析

3.3.1 字符嵌入对比试验

为选择最优文本嵌入模型, 分别采用随机生成字向量、使用预训练语言模型 BERT 和 Word2Vec 训练生成的向量作为字符嵌入, 在 BiLSTM-CRF 模型上进行效果对比试验。3 种方法结果对比如图 9 所示。可以看出, 基于 Word2Vec 的模型在苹果病虫害语料数据集上 F1 值表现最好。虽然基于 BERT 嵌入的模型对应的精确率最高, 但是召回率却表现最差。推测其原因, 它是由通用语料训练出来的词向量, 缺乏苹果病虫害领域的强特征信息。试验结果表明使用 Word2Vec 的字符嵌入模型有助于提高领域数据的实体识别准确度。

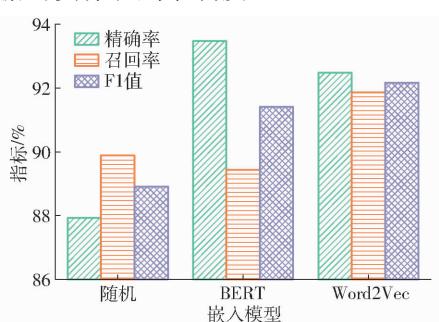


图 9 3 种不同嵌入模型试验结果对比

Fig. 9 Results of three different embedding models

3.3.2 不同注意力机制对比试验

为验证不同注意力机制对词典融合的影响, 开展了融合方案的对比选择试验。试验基准模型为词典信息特征 + 字形特征 + BiLSTM + PCSA + CRF, 分别使用静态词频、注意力机制、自注意力机制、多头注意力机制和通道注意力机制, 共 5 种方式对词典特征进行融合, 试验结果如表 5 所示。

由于本文将 4 类词当成不同的特征通道, 通道注意力机制通过强调特征通道的权重, 提供了更精

表 5 词典不同融合方式的模型性能对比

Tab. 5 Model performance comparison of

different fusion methods of dictionary

方案	具体方法	精确率	召回率	F1 值
静态	静态词频	95.60	89.01	92.19
	注意力机制	95.40	89.44	92.32
	自注意力机制	94.25	88.36	91.21
	多头注意力机制	92.48	91.87	92.17
动态	通道注意力机制	95.76	92.46	94.08

细的通道调整方式。故基于通道注意力机制的分配方案在各项指标上均有明显改善, P 、 R 和 F1 值分别比静态嵌入提高 0.16、3.45、1.89 个百分点。虽然注意力机制和多头注意力机制能关注序列中的特定部分来增强模型性能, 但这并没有强调特征通道之间的差异, 导致模型难以根据通道的重要性进行优化, 其性能与静态融合的方案相差不大。而自注意力机制擅长捕捉序列内部的关系, 弱化词之间的关系, 其 F1 值比静态融合的方案下降 0.98 个百分点。综上使用通道注意力机制动态嵌入词集, 可以增强模型区分 4 类词集的重要程度, 比静态嵌入的 SoftLexicon 模型能更充分地挖掘到外部词汇信息, 进而使模型整体性能得到提升。

3.3.3 不同模型对比试验

选取 4 种当前常用同类模型进行性能比较, 其中以 BiLSTM-CRF 为基准模型, 对比结果如表 6 所示。可以看到, 本文模型 P 、 R 和 F1 值分别达到 95.76%、92.46%、94.08%, 均明显高于其他对比模型, 表明本文模型对目标实体的识别性能较好。

表 6 不同模型性能对比

Tab. 6 Performance comparison of different models

模型	精确率	召回率	F1 值
BiLSTM-CRF	87.96	89.89	88.91
BERT-BiLSTM-CRF	93.47	89.44	91.41
Lattice-LSTM	93.92	90.06	91.95
SoftLexicon	95.17	89.22	92.10
本文	95.76	92.46	94.08

进一步分析可能原因, 对于 BiLSTM-CRF 模型, 由于单一的字符信息不能弥补词信息缺乏导致的识别性能下降, 故基于字符的 BiLSTM-CRF 模型在苹果病虫害识别任务中性能变差, F1 值仅为 88.91%。BERT 是经过超大型语料库训练好的语言模型, 使字向量能包含丰富的上下文语义信息, 因而使用后其 F1 值较基准模型提高 2.5 个百分点。Lattice-LSTM 模型由于引入了潜在的词信息, 其 F1 值比基准模型提高 3.04 个百分点。为提升训练速

度、简化模型,SoftLexicon 模型采用将词典匹配词分成 4 类词集并赋予静态权重的方法,F1 值达到 92.10%,性能较基准模型得到明显改善,但是该模型却出现精确率较高而召回率低的试验现象。例如用该模型识别“双胍三辛烷基苯磺酸盐”实体时,只能错误识别出实体的一部分“三辛烷基苯磺酸盐”。而本文模型集成了动态的词典信息和字符的字形特征,并利用了 PCSA 模块增强特征提取能力,有效弥补了同类模型的不足,因而在苹果病虫害领域实体识别中显现优势。

不同模型对苹果病虫害各类实体的识别结果如图 10 所示。本文模型对为害部位实体的识别效果与 SoftLexicon 模型基本持平,却明显高于其他模型。对其余 5 类实体,本文模型的 F1 值较对比模型均有不同程度提升,这也表明了所研究方法对苹果病虫害领域实体识别性能的提升是整体有效的。病害病原实体由于存在罕见字通常难以识别,本文通过动态融合词典信息和引入字形信息,增强了字的上下文语义,其识别性能较通用模型的提升效果显著。同时借助 PCSA 层的引入,模型能发现重要位置词“又称”的语义,进而可分辨出“又称”后面的实体如“粗皮病”、“大星病”和“褐纹病”为别名实体,而其他模型可能会将其误判为病虫害实体。因此本文模型对病虫害别名实体识别的性能要好于其他对比模型。综合来看,本方法在 6 类实体识别中的性能提升表现均衡,没有出现类似 SoftLexicon 模型在虫害类实体识别效果好(F1 值为 95.83%)、而在别名类实体识别效果差的不均衡现象(F1 值为 75.00%)。

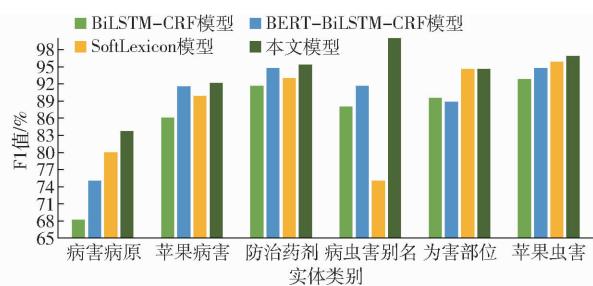


图 10 各类实体在不同模型的 F1 值
Fig. 10 F1-score of each entity in different models

在苹果病虫害数据集中,稀有且具挑战性实体主要位于“病害病原”一类中。同时,由于使用“BIOES”标记方案来标记文本数据中的实体,“O”标签(非实体部分)的比例通常远大于实体部分。因此大部分标记可能都是非实体,属于分类任务中正负样本比例严重失衡的情况。而 G-mean(Geometric mean)是一种评估分类模型性能的指标,尤其适用于处理不平衡数据集^[29],它计算敏感度(Sensitivity)和特异性(Specificity)指标平均值。

其中敏感度评价模型正确识别实体能力,而特异性评价模型正确忽略非实体能力。G-mean 的计算公式为

$$G = \sqrt{S_1 S_2} \quad (18)$$

式中 S_1 ——敏感度,即真阳性率

S_2 ——特异性,即真阴性率

为充分体现模型在稀有实体上的识别性能,本文使用 G-mean 计算每个实体类别识别性能,评价模型不仅能识别常见的非实体,且还能体现在样本较少的实体类别上的识别性能。试验结果如表 7 所示,可以看出对于稀有且具有挑战性的“病害病原”实体,本文的 G-mean 值为 0.9087,高于对比模型,表明模型对于该类实体识别的良好性能。

表 7 各实体在不同模型的 G-mean 值

Tab. 7 G-mean values of each entity in different models

实体	模型			
	BiLSTM – CRF	BERT – BiLSTM – CRF	SoftLexicon	本文模型
病害病原	0.8339	0.8501	0.8891	0.9087
苹果病害	0.8941	0.9180	0.9020	0.9266
防治药剂	0.9213	0.9607	0.9380	0.9630
病虫害别名	0.7968	0.8041	0.7352	0.8320
为害部位	0.9347	0.9332	0.9601	0.9568
苹果虫害	0.9563	0.9584	0.9719	0.9788

3.3.4 消融试验

为有针对性地验证引入动态词典特征、字形特征和 PCSA 模块对模型识别效果的影响,设计针对这 3 部分的消融试验,试验结果如表 8 所示。

表 8 消融试验比较结果

Tab. 8 Comparison results of ablation experiments

试验序号	模型结构			精确率	召回率	F1 值
	动态词典特征	字形特征	PCSA			
1	×	√	√	93.21	88.79	90.95
2	√	×	√	94.85	91.38	93.08
3	√	√	×	94.87	91.59	93.20
4	√	√	√	95.76	92.46	94.08

注:√ 表示使用模块,× 表示未使用模块。

从表 8 可以看到,在去除动态词典特征部分后,模型 F1 值为 90.95%,较第 4 组试验下降 3.13 个百分点。其原因在于动态词典特征能够增强词汇信息,特别是对于识别含有罕见字的实体,模型能够获得与罕见字相关联的有效特征,进而帮助判断。同时,由于借助通道注意力机制动态地给匹配词赋予权重,使模型可以区分不同词的重要程度。

由于中文汉字的四角号码是根据字的结构组

织,其包含字的字形特征。在去除该特征部分后,模型 F1 值为 93.08%,较第 4 组试验下降 1 个百分点,证明了字形特征对模型性能的提升有促进作用。同时从试验 1、2、4 的结果中可以看出,试验 1 的 F1 值下降程度更大,表明动态词典特征比字形特征所包含的信息量更多,对模型性能影响也更大。

在去除 PCSA 模块后,模型 F1 值为 93.20%。由于在 BiLSTM 网络输出后增加 PCSA 模块,该模块由两个不同尺度的卷积层组成并行结构进行特征提取,同时借助空间注意力网络的二次处理让模型关注重要位置的特征信息,进而忽视冗余信息。其在 F1 值上相较于第 4 组试验下降 0.88 个百分点。

3.3.5 PCSA 应用分析

试验选取 BiGRU^[30]、BiLSTM、Transformer 模型进行对比,比较有无 PCSA 模块性能差异。试验结果如表 9 所示,引入 PCSA 模块后,表 9 中各序列编码模型的效果都有不同程度的提升,表明 PCSA 模块的改善作用具有一定的通用性。PCSA 利用两个不同的卷积处理不同尺度的语义信息,同时借助 SAM 网络发现语句中重要位置的字信息,并赋予更大的权重。因此,引入 PCSA 将提升模型对输入特征信息的进一步挖掘。同时试验在基于 BiLSTM 的编码模型中,苹果病虫害数据集上识别效果最好,表明 BiLSTM 与 PCSA 组合的性能相对优异。

表 9 PCSA 应用效果对比

Tab. 9 Comparison of PCSA application results %

序列编码模型	精确率	召回率	F1 值
BiGRU	94.61	90.73	92.63
BiGRU + PCSA	96.77	90.30	93.42
BiLSTM	94.87	91.59	93.20
BiLSTM + PCSA	95.76	92.46	94.08
Transformer	93.26	89.44	91.31
Transformer + PCSA	94.18	90.73	92.43

为验证 PCSA 模块结构的合理性,试验改变 PCSA 模块的结构并对比。结构 A、B 分别使用 1×3 、 1×5 的卷积核提取不同角度的语义信息,结构 C (PCSA) 利用两个不同的卷积构成并行结构。同时考虑多数现有研究常使用多头注意力机制^[31] (Multi-head attention, MHA) 来提高序列编码层的特征提取能力,本文也对比使用 PCSA 和 MHA 的模型识别效果。试验结果如表 10 所示。PCSA 试验 F1 值为 94.08%,MHA 试验 F1 值为 91.83%。PCSA 比 MHA 有更好的识别效果,表明 PCSA 比常用的多头注意力机制有更好的特征提取能力。由于 PCSA 融合结构 A、B 形成并行组合,具备同时处理

两个不同尺度语义信息能力,比单独结构 A、B F1 值分别提高 0.72、0.38 个百分点。这表明并行结构能有效提取丰富的语义信息。

表 10 不同结构 PCSA 的试验结果

Tab. 10 Results of PCSA with different structures

结构	精确率	召回率	F1 值	%
结构 A	95.91	90.95	93.36	
结构 B	96.15	91.38	93.70	
结构 C (PCSA)	95.76	92.46	94.08	
MHA	94.12	89.66	91.83	

3.3.6 错误分析

为验证本文模型能更好识别出苹果病虫害实体,对测试数据集中一个实例进行分析,不同模型预测结果如表 11 所示,本例中的“叶枯病”在训练集中出现 17 次。

表 11 不同模型预测结果

Tab. 11 Results of different model prediction examples

实例	苹果叶枯病的致病菌为炭疽叶枯病菌
实例中正确的实体	苹果叶枯病(苹果病害)的致病菌为炭疽叶枯病菌(病害病原)
BiLSTM - CRF 预测	苹果叶枯病(苹果病害)的致病菌为炭疽叶枯病菌(苹果病害)
BERT - BiLSTM - CRF 预测	苹果叶枯病(苹果病害)的致病菌为炭疽叶枯病菌(苹果病害)
SoftLexicon 预测	苹果叶枯病(苹果病害)的致病菌为炭疽叶枯病菌(病害病原)
本文模型预测	苹果叶枯病(苹果病害)的致病菌为炭疽叶枯病菌(病害病原)

由表 11 可以看出,实例中的“苹果叶枯病”4 种模型正确识别为苹果病害实体,对于“炭疽叶枯病菌”病害实体,BiLSTM - CRF 和 BERT - BiLSTM - CRF 模型都出现边界识别错误,进而识别成误导性高的“叶枯病”实体。SoftLexicon 模型虽然通过词典特征增强了信息,但是由于“叶枯”字眼更常见,其静态词频过高,导致模型过分关注,只能将“炭疽叶枯病菌”实体错误地识别为其部分实体“叶枯病菌”。本文模型通过动态调整权重,词典特征可以更好地与上下文融合,因此做出正确的预测。

4 结论

(1) 构建了苹果病虫害专业语料数据集,提出了融合动态词典特征和 CBAM 的命名实体识别方法。

(2) 针对病害病原和防治药剂等实体中的罕见字语义提取困难、实体类别难以区分的问题,在基于

字的 BiLSTM-CRF 基础上,在嵌入层中融合了动态词典信息和汉字的字形信息,解决罕见字语义提取困难的问题;在序列编码层和 CRF 层中间新增 PCSA 模块,关注上下文重要信息,解决实体类型

相似而难以辨别的问题。经验证,本文模型自建语料数据集精确率、召回率和 F1 值分别为 95.76%、92.46%、94.08%,均高于当前常用模型。

参 考 文 献

- [1] 霍学喜,刘天军,刘军弟,等. 2020 年度中国苹果产业发展报告(精简版)[J]. 中国果菜,2022, 42(2): 1–6.
HUO Xuexi, LIU Tianjun, LIU Jundi, et al. China apple industry development report in 2020 [J]. China Fruit & Vegetable, 2022, 42(2): 1–6. (in Chinese)
- [2] 焦凯楠,李欣,朱容辰. 中文领域命名实体识别综述[J]. 计算机工程与应用, 2021, 57(16): 1–15.
JIAO Kainan, LI Xin, ZHU Rongchen. Overview of Chinese domain named entity recognition [J]. Computer Engineering and Applications, 2021, 57(16): 1–15. (in Chinese)
- [3] 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)
- [4] AN Y, XIA X, CHEN X, et al. Chinese clinical named entity recognition via multi-head self-attention based BiLSTM-CRF [J]. Artificial Intelligence in Medicine, 2022, 127: 102282.
- [5] XIONY Y, PENG H, XIANG Y, et al. Leveraging multi-source knowledge for Chinese clinical named entity recognition via relational graph convolutional network[J]. Journal of Biomedical Informatics, 2022, 128: 104035.
- [6] LI Y, DU G, XIANG Y, et al. Towards Chinese clinical named entity recognition by dynamic embedding using domain-specific knowledge[J]. Journal of Biomedical Informatics, 2020, 106: 103435.
- [7] GUO X, LU S, TANG Z, et al. CG-ANER: enhanced contextual embeddings and glyph features-based agricultural named entity recognition[J]. Computers and Electronics in Agriculture, 2022, 194: 106776.
- [8] GUO X, ZHOU H, SU J, et al. Chinese agricultural diseases and pests named entity recognition with multi-scale local context features and self-attention mechanism[J]. Computers and Electronics in Agriculture, 2020, 179: 105830.
- [9] 李林,周晗,郭旭超,等. 基于多源信息融合的中文农作物病虫害命名实体识别[J]. 农业机械学报, 2021, 52(12): 253–263.
LI Lin, ZHOU Han, GUO Xuchao, et al. Named entity recognition of diseases and insect pests based on multi source information fusion [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(12): 253–263. (in Chinese)
- [10] 杨璐,张恬,郑丽敏,等. 兽药致病命名实体 Att-Aux-BERT-BiLSTM-CRF 识别[J]. 农业机械学报, 2022, 53(3): 294–300.
YANG Lu, ZHANG Tian, ZHENG Limin, et al. Recognition of animal drug pathogenicity named entity based on recognition of animal drug pathogenicity named entity based on Att-Aux-BERT-BiLSTM-CRF [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(3): 294–300. (in Chinese)
- [11] 郑丽敏,任乐乐. 采用融合规则与 BERT-FLAT 模型对营养健康领域命名实体识别[J]. 农业工程学报, 2021, 37(20): 211–218.
ZHENG Limin, REN Lele. Named entity recognition in the domain of nutrition and health using fusion rules and BERT-FLAT model [J]. Transactions of the CSAE, 2021, 37(20): 211–218. (in Chinese)
- [12] 蒲攀,张越,刘勇,等. Transformer 优化及其在苹果病虫命名实体识别中的应用[J]. 农业机械学报, 2023, 54(6): 264–271.
PU Pan, ZHANG Yue, LIU Yong, et al. Transformer optimization and application in named entity recognition of apple diseases and pests [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(6): 264–271. (in Chinese)
- [13] LI X, MENG Y, SUN X, et al. Is word segmentation necessary for deep learning of Chinese representations? [C] // 57th Annual Meeting of the Association for Computational Linguistics, 2019: 3242–3252.
- [14] ZHANG Y, YANG J. Chinese NER using lattice LSTM [C] // Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics, 2018: 1554–1564.
- [15] LIU W, XU T, XU Q, et al. An encoding strategy based word-character LSTM for Chinese NER [C] // Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2019: 2379–2389.
- [16] MA R, PENG M, ZHANG Q, et al. Simplify the usage of lexicon in Chinese NER [C] // Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, 2020: 5951–5960.
- [17] ZHANG J, GUO M, GENG Y, et al. Chinese named entity recognition for apple diseases and pests based on character augmentation[J]. Computers and Electronics in Agriculture, 2021, 190: 106464.
- [18] LIU J, GAO L, GUO S, et al. A hybrid deep-learning approach for complex biochemical named entity recognition [J]. Knowledge-Based Systems, 2021, 221: 106958.
- [19] RONRAN C, LEE S. Effect of character and word features in bidirectional LSTM-CRF for NER [C] // 2020 IEEE International

- Conference on Big Data and Smart Computing, 2020;613–616.
- [20] LAMPLE G, BALLESTEROS M, SUBRAMANIAN S, et al. Neural architectures for named entity recognition [C] // 15th Conference of the North American Chapter of the Association for Computational Linguistics, 2016;260–270.
- [21] DEVLIN J, MING-WEI C, LEE K, et al. BERT: pre-training of deep bidirectional transformers for language understanding [C] // 2019 Conference of the North American Chapter of the Association for Computational Linguistics, 2019;4171–4186.
- [22] SUN Z, LI X, SUN X, et al. ChineseBERT: Chinese pretraining enhanced by glyph and pinyin information [C] // Joint Conference of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing, 2021;2065–2075.
- [23] MIKOLOV T, CHEN K, CORRADO G, et al. Efficient estimation of word representations in vector space [C] // 1st International Conference on Learning Representations, 2013;1–12.
- [24] 郭旭超,唐詹,刁磊,等. 基于部首嵌入和注意力机制的病虫害命名实体识别[J]. 农业机械学报, 2020, 51(增刊2): 335–343.
- GUO Xuchao, TANG Zhan, DIAO Lei, et al. Recognition of Chinese agricultural diseases and pests named entity with joint radical-embedding and self-attention mechanism [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51 (Supp. 2) : 335 – 343. (in Chinese)
- [25] 孙振,李新福. 多特征融合的中文电子病历命名实体识别[J]. 计算机工程与应用, 2023,59(23) : 136 – 144.
- SUN Zhen, LI Xinfu. Named entity recognition of Chinese electronic medical records based on multi-feature fusion [J]. Computer Engineering and Applications, 2023,59(23) : 136 – 144. (in Chinese)
- [26] SUNDERMEYER M, SCHLUTER R, NEY H. LSTM neural networks for language modeling [C] // 13th Annual Conference of the International Speech Communication Association, 2012;194 – 197.
- [27] WOO S, PARK J, LEE J, et al. CBAM: convolutional block attention module [C] // 15th European Conference on Computer Vision, 2018;3 – 19.
- [28] LIU Y, ZHOU Y, WEN S, et al. A strategy on selecting performance metrics for classifier evaluation [J]. International Journal of Mobile Computing and Multimedia Communications, 2014, 6(4) : 20 – 35.
- [29] ESPINDOLA R P, EBECKEN N F. On extending f-measure and g-mean metrics to multi-class problems [J]. WIT Transactions on Information and Communication Technologies, 2005,35 : 25 – 34.
- [30] CHO K, VAN MERRIENBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation [C] // Doha, Qatar, Association for Computational Linguistics (ACL), 2014;1724 – 1734.
- [31] VASWANI A, SHAZER N, PARMAR N, et al. Attention is all you need [C] // Advances in Neural Information Processing Systems, 2017;5999 – 6009.

(上接第 238 页)

- [18] 魏忠彩,王兴欢,李学强,等.履带自走式分拣型马铃薯收获机设计与试验[J].农业机械学报,2023,54(2) :95 – 106.
- WEI Zhongcai, WANG Xinghuan, LI Xueqiang, et al. Design and experiment of crawler self-propelled sorting type potato harvester [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023,54 (2) :95 – 106. (in Chinese)
- [19] 孟志军,王昊,付卫强,等.农业装备自动驾驶技术研究现状与展望[J].农业机械学报,2023,54(10) :1 – 24.
- MENG Zhijun, WANG Hao, FU Weiqiang, et al. Research status and prospects of agricultural machinery autonomous driving [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023,54 (10) :1 – 24. (in Chinese)
- [20] 刘兆朋,张智刚,罗锡文,等.雷沃 ZP9500 高地隙喷雾机的 GNSS 自动导航作业系统设计[J].农业工程学报, 2018, 34(1) : 15 – 21.
- LIU Zhaopeng, ZHANG Zhigang, LUO Xiwen, et al. Design of automatic navigation operation system for Lovol ZP9500 high clearance boom sprayer based on GNSS [J]. Transactions of the CSAE, 2018, 34(1) : 15 – 21. (in Chinese)
- [21] RUSTAMOV R B, HASANOVA S, ZEYNALOVA M H. Multi-purposeful application of geospatial data [M] // LEE J. Introduction to Navigation Systems. London: IntechOpen, 2018: 3 – 18.
- [22] 谭宝成,邓子豪.GPS 导航系统下坐标转换及应用[J].西安工业大学学报,2014,34(6) :504 – 510.
- TAN Baocheng, DENG Zihao. Realization of the coordinate transformation method in GPS navigation system [J]. Journal of Xi'an Technological University, 2014,34 (6) :504 – 510. (in Chinese)
- [23] 宋丽,艾长胜,孙崇书,等.基于高精度卫星差分定位的组合导航研究[J].现代信息科技,2022,6(15) :37 – 40,44.
- SONG Li, AI Changsheng, SUN Chongshu, et al. Research on integrated navigation based on high precision satellite differential positioning [J]. Modern Information Technology, 2022,6(15) :37 – 40,44. (in Chinese)