

doi:10.6041/j.issn.1000-1298.2022.11.032

基于改进 CASREL 的水稻施肥知识图谱信息抽取研究

周俊 郑彭元 袁立存 戈为溪 梁静

(南京农业大学工学院, 南京 210031)

摘要:为实现水稻施肥知识图谱自动化构建,为后续构建水稻施肥决策系统提供基础,定义了水稻施肥体系数据结构并制作水稻施肥数据集,结合水稻施肥数据特点,添加单位标注器,并改进 CASREL 解码加入隐藏层,提出了基于 RoBERTa-wwm 编码+改进 CASREL 解码的信息抽取模型,同时针对编码与解码环节进行试验对比。结果表明,基于该模型的 F1 值达到 91.86%,与对比模型相比有较为显著的提升。基于改进 RoBERTa-wwm-CASREL 的信息抽取模型能有效提高水稻施肥信息抽取效果,为水稻施肥知识图谱构建以及施肥决策系统提供基础。

关键词:水稻施肥;知识图谱;单位标注器;CASREL 解码;RoBERTa-wwm 编码

中图分类号:TP391 文献标识码:A 文章编号:1000-1298(2022)11-0314-09

OSID:



Knowledge Graph Information Extraction for Rice Fertilization Based on Improved CASREL

ZHOU Jun ZHENG Pengyuan YUAN Licun GE Weixi LIANG Jing

(College of Engineering, Nanjing Agricultural University, Nanjing 210031, China)

Abstract: In order to construct a rice fertilizer knowledge structure, based on the existing rice fertilizer unstructured data information, a rice fertilizer knowledge graph entity and relationship knowledge structure was proposed and designed, through which the existing rice fertilizer information in the network was stored in the knowledge graph as structured data; in order to extract a large amount of information to be stored in the knowledge graph, and at the same time, for the information extraction i. e., the existence of the overlapping triad problem, a rice fertilizer information extraction model based on RoBERTa-wwm coding + improved CASREL decoding was proposed, and the model was improved according to the characteristics of rice fertilizer data, and relevant experimental comparisons were conducted in coding and decoding, respectively. The results showed that the F1 value of this rice fertilizer information extraction model reached 91.86%, which was a significant improvement in extraction effect compared with the comparison model. Therefore, it can be concluded that the information extraction model based on the improved RoBERTa-wwm-CASREL can effectively improve the extraction effect of rice fertilizer information, which provided a basis for the next step of constructing rice fertilizer knowledge map and rice fertilizer decision system.

Key words: rice fertilization; knowledge mapping; unit labeller; CASREL decoding; RoBERTa-wwm encoding

0 引言

水稻是世界三大主要粮食作物之一^[1],是世界上 65% 以上人口的主粮,而我国是世界上水稻生产量、消费量最多的国家^[2];增加化肥使用量是增加水稻产量最直接的方式之一^[3],但会对土壤与环境

造成影响,因此水稻的合理施肥对水稻生产至关重要。由于我国各地区土壤种类复杂,相关研究都重点集中在作物本身生长机理而忽略了土壤肥力的表达水平,从而导致已有的水稻施肥信息系统通用性差。

随着智慧农业的兴起,产生了大量的农业信

收稿日期:2021-12-28 修回日期:2022-04-08

基金项目:国家重点研发计划项目(2019YFD0900705、2017YFD0700502)

作者简介:周俊(1974—),男,教授,博士生导师,主要从事农业装备智能化技术和农业机器人研究,E-mail:zhoujun@njau.edu.cn

息数据^[4]。这些非结构化的数据中包含了农业相关的关键信息,例如水稻等农作物施肥、播种、施药。知识图谱作为人工智能的重要组成部分,广泛应用于各个领域。知识图谱能够将不同类型的实体、概念进行组合进而以可视化的形式展示知识间的结构关系^[5-6],极大地提高了信息检索的效率。相关研究者将知识图谱应用到农业领域从而促进农业信息技术的进步,袁培森等^[7]提出了一种对水稻的基因、环境、表型等表型组学实体进行关系分类的方法,进而改善水稻表型知识图谱中实体关系抽取问题。于合龙等^[8]利用知识图谱对水稻病虫害领域复杂的非结构化数据信息进行结构化存储,为水稻病虫害关联检索及智能诊断提供理论依据。吴赛赛^[9]利用知识图谱以结构化的形式描述实体间复杂关系的优势,提出了一种基于深度学习的作物病虫害知识图谱构建方法。但是这些知识图谱的规模化、体系化方面仍存在许多不足,在实现非结构化数据的有效提取、解决文本重叠关系提取等方面仍是当前面临的一大挑战^[10]。此外知识图谱在农业领域的应用及研究处于初级阶段,利用知识图谱从分散性、多种类、连贯性差的农业数据中提取关键的、有价值的农业信息是未来研究的重点。

如今人工智能已经渗透到各个领域,其中知识图谱表现出了很高的实际应用价值,根据领域构建不同的知识图谱,同时结合不同算法能够极大地提高解决问题的效率。马展等^[11]为提高应用程序接口 API 的检索效率,提出多源信息融合的 API 知识图谱构建方法。在医学领域,张兴等^[12]通过在网络中提取与儿童病护理相关的数据,构建关于儿童病护理的问答数据集,然后利用算法及自然语言处理相关模型实现人工特征转换效率的提高。在航空领域,大数据平台建模也得到飞速发展,但是由于数据不能实现跨专业的贯通导致数据价值不能被全面挖掘。韩吉南等^[13]通过构建航天装备数据知识图谱,利用大数据、人工智能知识挖掘航天数据,实现数据的规范化管理。

知识图谱是结构化数据表示中最有效、最简洁、最强大的方法之一。而信息抽取作为构建知识图谱的基础技术,是大规模构建知识图谱的关键一步。面向知识图谱的信息抽取主要是针对关系三元组进行抽取,而重叠三元组问题会极大影响抽取结果。WEI 等^[14]针对重叠三元组问题提出了 CASREL 模型,并与 ZHENG 等^[15]提出的 NovelTagging, ZENG 等^[16]提出的 CopyR, FU 等^[17]提出的 GraphRel,以及不同编码 random - CASREL、LSTM -

CASREL、BERT - CASREL 进行消融实验,证明了 CASREL 模型在应对重叠三元组情况的优越性。

本文以水稻施肥信息为研究对象,构建水稻施肥知识结构,根据现有的水稻施肥非结构化数据信息,提出并设计水稻施肥知识图谱实体及关系知识结构,将网络中现存的水稻施肥信息通过该知识结构以结构化数据存储到知识图谱中;为提取大量信息存入知识图谱中,同时针对信息抽取即重叠三元组问题,提出基于 RoBERTa - wwm 编码 + 改进 CASREL 解码的信息抽取模型,进行一系列消融实验,并根据水稻施肥数据特点对模型进行改进,以期实现句子级别的信息抽取,为构建水稻施肥知识图谱以及制作水稻施肥决策系统提供数据基础。

1 水稻施肥信息数据集

目前,有关水稻施肥结构化数据的资源有限,且数据可信度参差不齐。因此,本文有关水稻施肥信息的数据集主要从中国知网和国家水稻数据中心获取,共节选原始数据 978 句用于数据集标注。

数据集作为模型的输入,用来对模型参数进行训练,模型训练效果部分取决于数据集的质量。由于本文关系种类大部分与水稻施肥信息相关,现存的开源数据集并不适用于本模型训练,因此采用人工标注的方法制作所需数据集。

1.1 水稻施肥关系种类

结合文献中水稻种植所需信息^[18-19],设计图 1 所示的水稻施肥体系数据结构,共 27 种关系。

其中,不同水稻品种之间以父本/母本及水稻类型(粳稻/籼稻)相互连接。对于每个水稻品种,储存其特征、栽培技术、适宜种植区域及产量表现作为其基本信息。同时,将种植实例以地区为单位与水稻品种相连接,储存实验地区的土壤养分情况并与所在省、市、区相连接。最后,将不同种植实例与种植地区相连接,并将施氮量、氮磷钾肥料配比、基肥穗肥配比及施肥时间、产量与种植实验相连接,形成完整的水稻施肥知识图谱结构。

对原始数据以句子为单位划分,并对数据集进行标注,标注格式为:句子,头实体,关系类型,尾实体。标注完成的数据集示例如表 1 所示。

1.2 水稻施肥信息数据集分配

将标注好的水稻施肥数据集以 5:2:3 的比例随机分配为训练集、验证集和测试集,其中训练集 506 条数据,验证集 189 条数据,测试集 283 条数据。各个数据集关系类型数量如表 2 所示,其中 N 表示一个句子中关系三元组的个数。

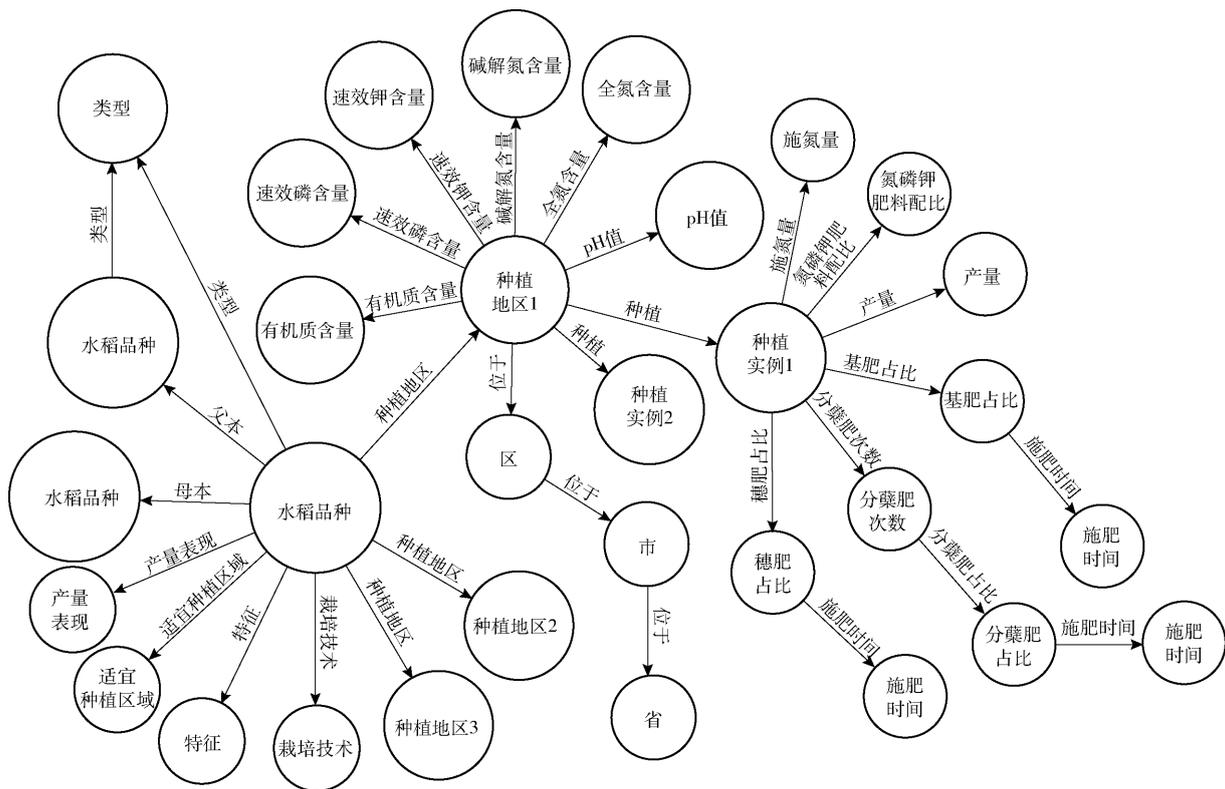


图1 水稻施肥体系数据结构

Fig. 1 Multivariate data structure of rice fertilization

表1 水稻施肥信息数据集示例

Tab. 1 Example of dataset of rice fertilization information

句子	头实体	关系类型	尾实体
南粳 3908, 粳型常规水稻, 江苏省农业科学院粮食作物研究所、江苏明天种业科技股份有限公司选育, 适宜在江苏省沿江及苏南地区种植。	南粳 3908	类型	粳型常规水稻
	南粳 3908	适宜种植地区	江苏省沿江及苏南地区
南粳 5718 一般亩施纯氮 18 ~ 20 kg, 控制氮肥施用量, 适当增加磷、钾肥用量。	南粳 5718	施氮量	亩施纯氮 18 ~ 20 kg 左右
	基肥	基肥占比	30%
其中基肥占 30%, 在最后一次把田平整前一次性施入。	基肥	施肥时间	最后一次把田平整前
氮肥运筹为基肥: 穗肥 = 8: 2。	基肥: 穗肥	基肥: 穗肥占比	8: 2
	土壤	pH 值	5.96
土壤类型为河淤土, 基本理化性状如下: pH 值 5.96, 有机质含量 12.51 g/kg, 全氮含量 0.89 g/kg, 速效磷含量 7.95 mg/kg, 速效钾含量 92 mg/kg。	土壤	有机质含量	12.51 g/kg
	土壤	全氮含量	0.89 g/kg
	土壤	速效磷含量	7.95 mg/kg
	土壤	速效钾含量	92 mg/kg

表2 水稻施肥数据集关系类型数量

Tab. 2 Data set relationship type quantity

数据集	N		
	1	2	≥3
训练集	357	87	62
验证集	148	30	11
测试集	222	45	16

2 水稻施肥信息抽取模型构建

为了构建抽取效果更好的水稻施肥信息抽取模型, 本文采用 Encoder - Decoder 结构对模型进行构

建, 模型流程图如图 2 所示。BERT 系列模型相较于 RNN、LSTM 等模型在编码环节效果更好, 且由于数据集为中文, 传统 BERT 模型并不能很好地适应中文语料, 因此选择 RoBERTa - wwm 作为模型的编码器 (Encoder) 结构; 本文数据集中多为重叠三元组 (多个关系三元组共享同一个实体), 传统信息抽取模型在应对该问题上效果欠佳, 而 CASREL 模型的级联二元标注结构能很好地处理该问题, 因此选择 CASREL 作为模型的解码器 (Decoder) 结构; 为使得通用模型在特定场合能取得更佳效果, 结合水稻施肥数据集的特征对该模型进行改进。

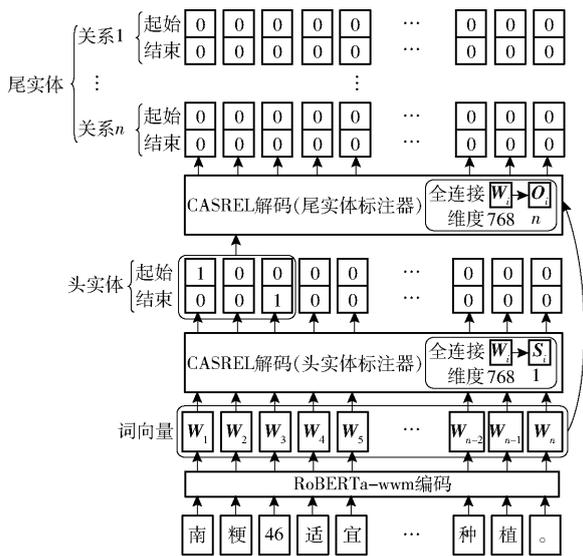


图 2 RoBERTa-wwm-CASREL 模型流程图

Fig. 2 RoBERTa-wwm-CASREL model flow chart

2.1 Encoder-Decoder 结构

Encoder-Decoder (编码器-解码器) 结构又被叫做 Seq2Seq 结构, 是深度学习中常见的模型框架之一^[20]。Encoder 由一个编码器将输入序列转化成一个固定维度的稠密向量, Decoder 阶段对这个向量进行解读并生成结果^[21]。Encoder-Decoder 结构将模型分为两部分, 这种结构可以有效解决在处理长距离序列化问题时造成的误差累积情况。

2.1.1 RoBERTa-wwm 编码模型

RoBERTa 模型是基于 BERT 模型的一种优化版本, 与 BERT 模型相同的是, RoBERTa 模型的结构也是由多层双向 Transformer 组成的^[22-24], 并对 BERT 模型进行了一系列优化^[25-26]。

由于 BERT 的系列模型都是以字为单位进行切分, Mask 操作也是以字为单位, 这种切分方法在中文语料中效果较差。全词掩码 (Whole word masking, WWM) 针对这一问题, 充分考虑了中文语料的分词操作, 以词为单位进行 Mask 操作。研究表明, 使用 WWM 的 BERT 系列模型在中文语料中取得了更好的效果^[27]。

2.1.2 CASREL 解码模型

CASREL 解码模型主要针对目前既有模型处理重叠关系三元组^[28] 效果不好的问题, 模型是一种级联二元标注框架, 基本思想是用两级联步骤提取三元组^[14]。首先, 从输入句子中检测出头实体。然后, 对于每个候选头实体检查所有可能的关系, 确定是否有一个关系可以将句子中的尾实体与该头实体联系起来。与这两个步骤相对应, 级联解码器由头实体标注器和特定关系的尾实体标注器组成。头实体标注器模块通过直接解码编码器产生的编码词向

量来识别输入句子中所有可能的头实体, 特定关系的尾实体标注器模块同时识别尾实体以及与头实体标注器获得的头实体的相关关系。

2.2 模型改进

在水稻施肥数据集中, 与施肥决策相关的数据大部分都在尾实体, 而尾实体多由数字加单位组成, 因此, 为了使模型的提取效果更好, 提高对包含上述尾实体的三元组的抽取能力, 本文在尾实体标注器的输入中加入了单位标注器模块。单位标注器模块在对句子进行编码的同时, 使用正则方法对句子中的单位符号进行匹配, 对匹配到的符号作为结束标注位并向前通过判断是否为中文字符的方法找到起始标注位, 将起始标注位到结束标注位标注为 1, 其余位标注为 0, 形成句子标注信息, 并在尾实体标注器解码时, 将标注信息与编码词向量和头实体标注器的结果相加, 使得该位置有更大的可能作为尾实体被抽取出来。

同时, 由于原 CASREL 模型头实体标注器和尾实体标注器均采用直接解码的方式, 三元组提取效果较差, 如果在原模型基础上加入一层隐藏层^[29], 考虑使用更多的参数来提高模型对水稻施肥信息抽取的效果, 但随着抽取到的信息增多, 也会造成模型精度下降。由于原模型训练结果精度较高, 因此加入维度为 1 024 的隐藏层, 在略降低精度的情况下, 提高模型对水稻施肥信息抽取的效果, 改进后的模型流程图如图 3 所示。

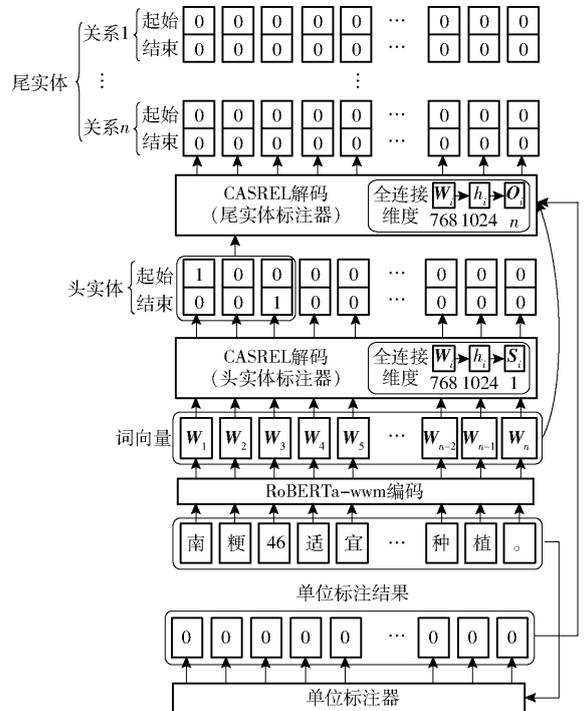


图 3 改进后 RoBERTa-wwm-CASREL 模型流程图

Fig. 3 Improved RoBERTa-wwm-CASREL model flow chart

3 模型训练结果与分析

3.1 训练环境

选择 Intel(R) Core(TM) i7-10700K CPU @ 3.80 GHz, GPU 为 NVIDIA GeForce RTX 3060 Ti, 16 GB 内存, Windows 10 操作系统, 运行环境为 Pytorch 1.9.0 + cuda 11.1。

3.2 参数设置

水稻施肥模型参数设置如下: 学习率 1×10^{-5} , 批量大小 6, 迭代次数 100, 梯度下降算法 ADAM。

3.3 算法性能评估指标

使用精确率(Precision)、召回率(Recall)、F1 值作为评价指标^[30], 其中, 精确率是指预测正确的三元组数与预测三元组总数的比值, 召回率是指预测正确的三元组数与实际三元组总数的比值^[31]。编码部分将 RoBERTa-wwm 与 BERT-base-chinese 和 BERT-wwm 进行对比, 解码部分将原 CASREL 模型与改进后模型进行对比。

3.4 模型信息抽取结果分析

3.4.1 不同梯度下降算法对比分析

本文对 RoBERTa-wwm-CASREL 模型进行了不同梯度下降算法^[32]的对比, 随机梯度下降算法(SGD)学习率选择 1×10^{-3} , F1 值训练过程如图 4 所示, 最终训练结果如图 5 所示。

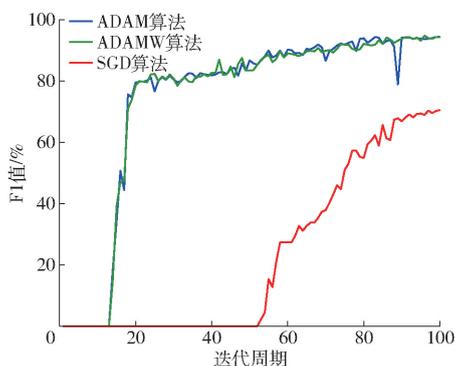


图 4 不同梯度下降算法 F1 值训练过程

Fig. 4 F1 value training process of different gradient descent algorithms

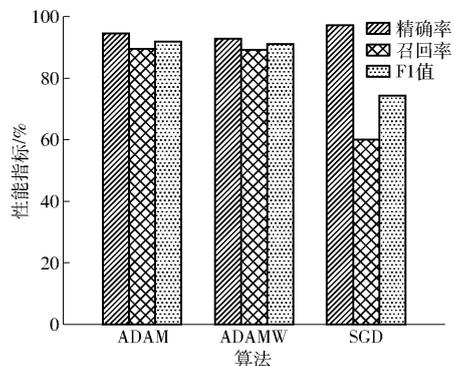


图 5 不同梯度下降算法训练结果

Fig. 5 Training results of different gradient descent algorithms

由图 4 可以看出, 相同迭代次数下, ADAM 算法和 ADAMW 算法的 F1 值高于 SGD 算法, ADAM 算法和 ADAMW 算法的优化速度始终高于 SGD 算法; ADAM 算法在训练过程中存在一定的波动, 第 90 轮迭代时, ADAM 算法波动较明显, 而 ADAMW 算法在整个训练过程中较为稳定。由图 5 可得, ADAM 算法的最终 F1 值为 91.86%, 略高于 ADAMW 算法, 而 SGD 算法 F1 值仅为 74.25%, 相对于另外两种算法结果较差; 但就精确率而言, SGD 算法的精度达到 97.11%, 而另外两种算法的精度均低于 95%。

3.4.2 不同批量大小对比分析

选择批量大小为 6、12、24 进行水稻施肥信息抽取试验, 梯度下降算法选用 ADAM 算法, 在 RoBERTa-wwm-CASREL 模型上的结果如表 3 所示。

表 3 本文模型不同批量大小时性能对比结果

Tab. 3 Comparison results of different batch size models

批量大小	精确率/%	召回率/%	F1 值/%	运行时间/s
6	94.34	89.51	91.86	940.41
12	95.40	84.91	89.85	633.66
24	98.22	70.59	82.14	567.45

由表 3 可以看出, 当批量大小为 6 时, 精确率达到 94.34%, F1 值达到 91.86%, 召回率为 89.51%; 随着批量大小的增加, 模型 F1 值不断下降, 所需时间减少。批量大小从 6 增加到 24, F1 值降低 9.72 个百分点, 所需时间减少 372.96 s。

3.4.3 解码模型对比分析

本文将改进后 CASREL 模型与原模型进行对比, 梯度下降算法选用 ADAM 算法, 批量大小为 6, 在本文数据集上进行训练并对结果进行对比分析, 模型训练过程如图 6 所示, 最终训练结果如表 4 所示。

由图 6 可以看出, 改进后模型的优化速度比原模型有一定的提升, 且 F1 值、精确率、召回率的训练过程均优于原模型, 且相对稳定。优化速度变快是由于在原模型中加入了单位标注器模块, 从而实现模型在训练过程中可以更简单、更快速地找到被标注的实体。

由表 4 可看出, 改进后模型精确率为 94.34%, 召回率为 89.51%, F1 值为 91.86%; 相比于原模型, 召回率提高 4.6 个百分点, F1 值提高 1.77 个百分点, 但精度降低 1.61 个百分点。而且改进后模型较原模型多预测 25 个三元组, 预测正确的三元组多 18 个。这是由于在原模型中加入了单位标注器模块的同时, 在

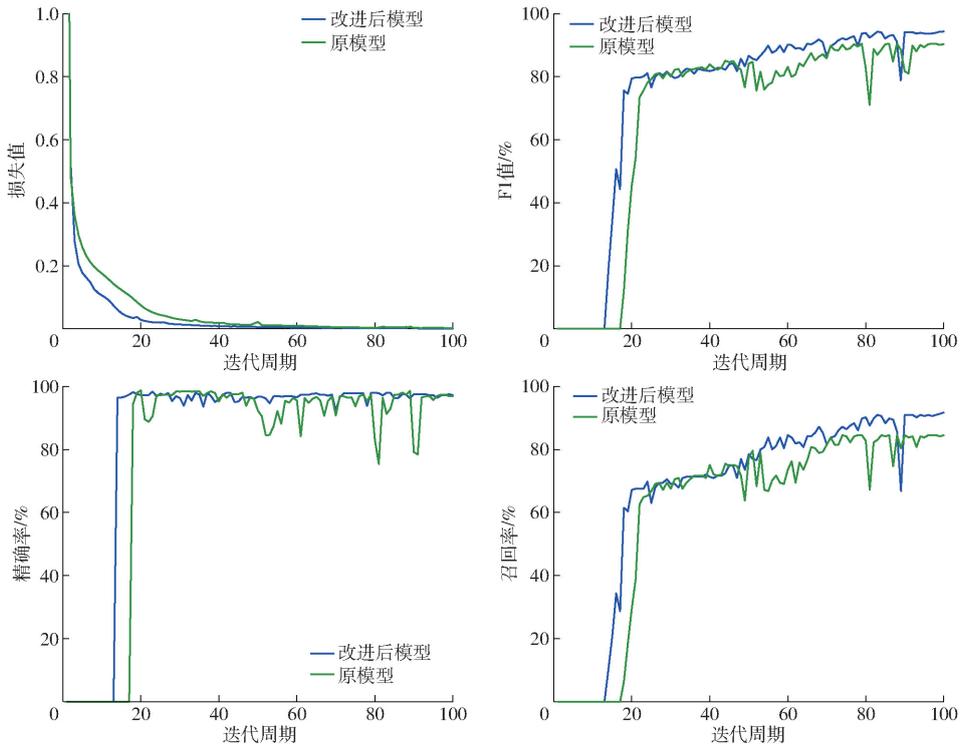


图 6 模型训练结果

Fig. 6 Model training results

表 4 解码模型对比结果

Tab. 4 Decoding model comparison results

模型	全部三元组数量	预测三元组数量	预测正确三元组数量	精确率/%	召回率/%	F1 值/%
原模型	391	346	332	95.95	84.91	90.09
改进后模型	391	371	350	94.34	89.51	91.86

解码过程中加入了隐藏层,使模型效果更好。

3.4.4 不同预训练模型编码对比分析

将 BERT - base - chinese、BERT - wwm - ext、RoBERTa - wwm - ext 模型分别作为水稻施肥信息模型的编码模型进行对比。BERT - base - chinese 是 Google 提供的基础中文预训练模型,BERT - wwm - ext 和 RoBERTa - wwm - ext 是 Google 基于 WWM 在 2019 年 5 月 31 日发布的一项 BERT 的升级版本,语料为 EXT 数据。EXT 数据包括中文维基百科、其他百科新闻、问答等数据,总词数达 54 亿。梯度下降算法选用 ADAM 算法,批量大小为 6,最终训练结果如表 5 所示。

表 5 不同编码模型对比结果

Tab. 5 Comparison results of different encoding models

模型	精确率	召回率	F1 值
BERT - base - chinese	78.87	71.61	75.07
BERT - wwm - ext	94.49	87.72	90.98
RoBERTa - wwm - ext	94.34	89.51	91.86

由表 5 可以看出,RoBERTa - wwm - ext 模型的精确率为 94.34%,召回率为 89.51%,F1 值为 91.86%,相对于 BERT - base - chinese 模型,精确率提高 15.47 个百分点,相较于 BERT - wwm - ext 编码,精确率降低 0.15 个百分点;而相较于 BERT - base - chinese 编码与 BERT - wwm - ext 编码,F1 值分别提高 16.79、0.88 个百分点;由此可见,基于 WWM 的 BERT - wwm - ext 编码,在中文任务上取得的效果远超出 BERT - base - chinese 编码,而 RoBERTa - wwm - ext 编码相对于 BERT - wwm - ext 编码应用了更多的参数,效果有一些提升。

3.5 模型应用

将《不同施氮量对水稻南粳 46 产量及品质的影响》^[33]一文以及国家水稻数据中心关于该品种的信息作为输入在原模型与改进后模型中进行试验,得到的水稻施肥三元组抽取结果如表 6 所示。

从表 6 中可以看出,模型对输入数据的抽取效果较好,水稻施肥决策所需信息基本抽取正确,改进后模型针对包含单位尾实体抽取效果有较大提升。同时发现模型对特定地点抽取效果较差,这是由于数据集的数量有限,若实体未在数据集中出现,会导致模型结果较差,针对这种情况,选择通过大量农业相关中文语料对编码模型进行预训练,可能会提高模型在该情况中的效果。

综上所述,改进后的 RoBERTa - wwm - CASREL 模型在进行水稻施肥信息抽取任务时,能有效提高

表6 水稻施肥三元组抽取结果

Tab.6 Results of rice fertilization triad extraction

头实体	关系类型	尾实体	原模型抽取结果	改进后模型抽取结果
试验	试验种植地区	上实农业园区	未识别出尾实体	未识别出尾实体
上实农业园区	位于	上海	未识别出头实体	未识别出头实体
土壤	有机质含量	1.08%	未识别出尾实体	正确
土壤	速效磷含量	9.23 mg/kg	正确	正确
土壤	速效钾含量	115 mg/kg	正确	正确
土壤	全氮含量	0.066%	未识别出尾实体	正确
土壤	pH值	8.11	未识别出尾实体	正确
品种	试验品种	南粳46	正确	正确
施氮量	施氮量	0、105、150、195、240、285、330、375 kg/hm ²	正确	正确
氮、磷、钾养分配比	肥料配比	1:0.3:0.3	未识别出头实体	未识别出头实体
基肥: 穗肥	基肥: 穗肥配比	8:2	识别错误头实体	识别错误头实体
基肥	施肥时间	最后一次耙田平整前	正确	正确
基肥	基肥占比	30%	正确	正确
分蘖肥	分蘖肥占比	20%	正确	正确
分蘖肥	分蘖肥占比	30%	正确	正确
分蘖肥	施肥时间	6月29日	正确	正确
分蘖肥	施肥时间	7月9日	正确	正确
穗肥	穗肥占比	20%	正确	正确
穗肥	施肥时间	8月6日	正确	正确
产量	产量	6 349.05、8 817.75、9 460.35、9 751.50、9 770.25、10 213.20、9 765.75、9 349.20 kg/hm ²	正确	正确
南粳46	父本	关东194	关系识别错误	关系识别错误
南粳46	母本	武香粳14	未识别出尾实体	未识别出尾实体
南粳46	类型	粳型常规水稻	正确	正确
南粳46	平均亩产	690.9 kg	正确	正确
南粳46	适宜种植地区	江苏省沿江及苏南地区	正确	正确
南粳46	一般亩施纯氮	18 kg左右	正确	正确

信息抽取率,同时,选择最优的编码模型在一定程度上也使得模型效果更佳。

4 结束语

提出了基于改进 RoBERTa - wwm - CASREL 模型的水稻施肥信息抽取方法。根据水稻施肥所需信息,定义了水稻施肥体系数据结构并制作了水稻施

肥数据集。结合水稻施肥数据特点,通过添加单位标注器和在 CASREL 解码中添加隐藏层来对模型进行改进。对比试验结果表明,改进后模型精确率、召回率与 F1 值分别达到 94.34%、89.51% 和 91.86%, 优于原模型。改进模型可以对水稻施肥数据进行有效的信息抽取,为构建水稻施肥知识图谱提供了数据基础。

参 考 文 献

- [1] 周平遥,张震,王华,等. 不同深施肥方式对稻田氨挥发及水稻产量的影响[J]. 农业环境科学学报, 2020,39(11): 2683-2691.
ZHOU Pingyao,ZHANG Zhen,WANG Hua,et al. Effects of deep fertilization methods on ammonia volatilization and rice yield in paddy fields[J]. Journal of Agro-Environment Science,2020,39(11):2683-2691. (in Chinese)
- [2] 胡根生. 侧深施肥用量对中籼杂交水稻生长和产量的影响[J]. 安徽农业科学, 2021,49(7):167-169.
HU Gensheng. Effects of different side-depth fertilization rates on the growth and yield of medium indica hybrid rice[J]. J. Anhui Agric. Sci., 2021,49(7): 167-169. (in Chinese)
- [3] 王爽,张平,龚明强,等. 不同施肥方式对水稻生产特性及经济效益的影响[J]. 安徽农业科学, 2021,49(22):155-157,160.
WANG Shuang,ZHANG Ping,GONG Mingqiang,et al. Effects of fertilization methods on production characteristics and economic benefits of rice[J]. J. Anhui Agric. Sci., 2021,49(22): 155-157,160. (in Chinese)
- [4] 赵春江. 智慧农业的发展现状与未来展望[J]. 华南农业大学学报, 2021,42(6):1-7.
ZHAO Chunjiang. Current situations and prospects of smart agriculture[J]. Journal of South China Agricultural University, 2021, 42(6): 1-7. (in Chinese)

- [5] 张海瑜, 陈庆龙, 张斯静, 等. 基于语义知识图谱的农业知识智能检索方法[J]. 农业机械学报, 2021, 52(增刊): 156–163. ZHANG Haiyu, CHEN Qinglong, ZHANG Sijing, et al. Intelligent retrieval method of agricultural knowledge based on semantic knowledge graph[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(Supp.): 156–163. (in Chinese)
- [6] 赵明, 杜亚茹, 杜会芳, 等. 植物领域知识图谱构建中本体非分类关系提取方法[J]. 农业机械学报, 2016, 47(9): 278–284. ZHAO Ming, DU Yaru, DU Huifang, et al. Research on ontology non-taxonomic relations extraction in plant domain knowledge graph construction[J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(9): 278–284. (in Chinese)
- [7] 袁培森, 李润隆, 王翀, 等. 基于 BERT 的水稻表型知识图谱实体关系抽取研究[J]. 农业机械学报, 2021, 52(5): 151–158. YUAN Peisen, LI Runlong, WANG Chong, et al. Entity relationship extraction from rice phenotype knowledge graph based on BERT[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(5): 151–158. (in Chinese)
- [8] 于合龙, 沈金梦, 毕春光, 等. 基于知识图谱的水稻病虫害智能诊断系统[J]. 华南农业大学学报, 2021, 42(5): 105–116. YU Helong, SHEN Jimgeng, BI Chunguang, et al. Intelligent diagnostic system for rice diseases and pests based on knowledge graph[J]. Journal of South China Agricultural University, 2021, 42(5): 105–116. (in Chinese)
- [9] 吴赛赛. 基于知识图谱的作物病虫害智能问答系统设计与实现[D]. 北京: 中国农业科学院, 2021. WU Saisai. Design and implementation of intelligent question and answering system for crop diseases and pests based on knowledge graph[D]. Beijing: Chinese Academy of Agricultural Sciences, 2021. (in Chinese)
- [10] 张博凯, 李想. 基于知识图谱的 Android 端农技智能问答系统研究[J]. 农业机械学报, 2021, 52(增刊): 164–171. ZHANG Bokai, LI Xiang. Design of agricultural question answering system based on knowledge graph[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(Supp.): 164–171. (in Chinese)
- [11] 马展, 王岩, 王微微, 等. 基于多源信息融合的 API 知识图谱构建[J]. 计算机系统应用, 2021, 30(12): 202–210. MA Zhan, WANG Yan, WANG Weiwei, et al. API knowledge graph construction based on multi-source information fusion[J]. Computer Systems & Applications, 2021, 30(12): 202–210. (in Chinese)
- [12] 张兴, 王海荣, 李明亮, 等. 基于知识图谱的儿童病问答模型构建[J]. 郑州大学学报(理学版), 2022, 54(2): 74–80. ZHANG Xing, WANG Hairong, LI Mingliang, et al. Construction of question answering model for children's diseases based on knowledge graph[J]. J. Zhengzhou Univ. (Nat. Sci. Ed.), 2022, 54(2): 74–80. (in Chinese)
- [13] 韩吉南, 袁鸿翼, 郑奎志, 等. 面向航天装备大数据的知识图谱体系[J]. 国防科技, 2021, 42(5): 40–46. HAN Jìnan, YUAN Hongyi, ZHENG Kuizhi, et al. Knowledge map system of big data platform for aerospace equipment[J]. National Defense Technology, 2021, 42(5): 40–46. (in Chinese)
- [14] WEI Z, SU J, WANG Y, et al. A novel cascade binary tagging framework for relational triple extraction[J]. arXiv preprint arXiv:1909.03227, 2019.
- [15] ZHENG S, WANG F, BAO H, et al. Joint extraction of entities and relations based on a novel tagging scheme[J]. arXiv preprint arXiv:1706.05075, 2017.
- [16] ZENG X, HE S, ZENG D, et al. Learning the extraction order of multiple relational facts in a sentence with reinforcement learning[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.
- [17] FU T, LI P, MA W. GraphRel: modeling text as relational graphs for joint entity and relation extraction[C] // Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics, 2019.
- [18] 胡香玉, 钟旭华, 林绿, 等. 水稻“三控”施肥技术在南方稻区的推广应用[J]. 广东农业科学, 2021, 48(10): 100–110. HU Xiangyu, ZHONG Xuhua, LIN Lü, et al. Promotion and application of the “three controls” technology for rice in Southern China[J]. Guangdong Agricultural Sciences, 2021, 48(10): 100–110. (in Chinese)
- [19] 王家宝, 程焱, 胡荣根, 等. 安徽省水稻施肥现状及技术需求[J]. 中国土壤与肥料, 2021(4): 162–171. WANG Jiabao, CHENG Yi, HU Ronggen, et al. Current situation and technical demand of rice fertilization in Anhui Province [J]. Soil and Fertilizer Sciences in China, 2021(4): 162–171. (in Chinese)
- [20] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C] // Advances in Neural Information Processing Systems, 2017.
- [21] 王博文, 王景升, 王统一, 等. 基于长短时记忆网络的 Encoder-Decoder 多步交通流预测模型[J]. 重庆大学学报, 2021, 44(11): 71–80. WANG Bowen, WANG Jingsheng, WANG Tongyi, et al. An Encoder-Decoder multi-step traffic flow prediction model based on long short-time memory network[J]. Journal of Chongqing University, 2021, 44(11): 71–80. (in Chinese)
- [22] 刘高军, 李亚欣, 段建勇. 基于混合注意力机制的中文机器阅读理解[J]. 计算机工程, 2022, 48(10): 67–72, 80. LIU Gaojun, LI Yaxin, DUAN Jianyong. Chinese machine reading comprehension based on hybrid attention mechanism[J]. Computer Engineering, 2021, 48(10): 67–72, 80. (in Chinese)
- [23] DEVLIN J, CHANG M W, LEE K, et al. BERT: pre-training of deep bidirectional transformers for language understanding [J]. arXiv preprint arXiv:1810.04805, 2018.
- [24] 史占堂, 王玉鹏, 赵凡, 等. 基于 CNN-Head Transformer 编码器的中文实体识别[J]. 计算机工程, 2022, 48(10): 73–60. SHI Zhantang, MA Yupeng, ZHAO Fan, et al. Chinese NER using CNN-Head Transformer encoder [J]. Computer Engineering, 2022, 48(10): 73–60. (in Chinese)
- [25] 王曙燕, 原柯. 基于 RoBERTa-WWM 的大学生论坛情感分析模型[J]. 计算机工程, 2022, 48(8): 292–298, 305. WANG Shuyan, YUAN Ke. Sentiment analysis model of college students forum based on RoBERTa-WWM [J]. Computer Engineering, 2022, 48(8): 292–298, 305. (in Chinese)
- [26] LIU Y, OTT M, GOYAL N, et al. RoBERTa: a robustly optimized BERT pretraining approach[J]. arXiv preprint arXiv:1907.11692, 2019.

- [27] CUI Yiming, CHE Wanxiang, LIU Ting, et al. Pre-training with whole word masking for Chinese BERT[J]. arXiv preprint arXiv:1906.08101, 2019.
- [28] 唐楠楠, 陈吉, 侯磊, 等. 融合注意力机制和指针标注的实体关系联合抽取方法[J]. 小型微型计算机系统, 2021;1-8. <https://kns.cnki.net/kcms/detail/21.1106.TP.20211217.1520.013.html>.
TANG Nannan, CHEN Ji, HOU Lei, et al. Joint extraction method of entity and relation based on attention mechanism and pointer annotation[J]. Journal of Chinese Computer Systems, 2021;1-8. (in Chinese)
- [29] 奚雪峰, 周国栋. 面向自然语言处理的深度学习研究[J]. 自动化学报, 2016,42(10):1445-1465.
XI Xuefeng, ZHOU Guodong. A survey on deep learning for natural language processing[J]. Acta Automatica Sinica, 2016, 42(10):1445-1465. (in Chinese)
- [30] 李晓静, 林海伦, 贾岩涛, 等. 融合页面结构与内容的在线百科实体标注方法[J]. 计算机科学与探索, 2015,9(10):1238-1246.
LI Xiaojing, LIN Hailun, JIA Yantao, et al. Online encyclopedia entities tagging method based on page structure and content [J]. Journal of Frontiers of Computer Science and Technology, 2015, 9(10):1238-1246. (in Chinese)
- [31] 鄂海红, 张文静, 肖思琪, 等. 深度学习实体关系抽取研究综述[J]. 软件学报, 2019,30(6):1793-1818.
E Haihong, ZHANG Wenjing, XIAO Siqi, et al. Survey of entity relationship extraction based on deep learning[J]. Journal of Software, 2019, 30(6):1793-1818. (in Chinese)
- [32] MU Yang, DING Wei, ZHOU Tianyi, et al. Constrained stochastic gradient descent for large-scale least squares problem[C]//ACM, 2013.
- [33] 陈小倩, 曹伟召, 左军, 等. 不同施氮量对水稻南粳46产量及品质的影响[J]. 现代农业科技, 2020(2):17-18.
CHEN Xiaqian, CAO Weizhao, ZUO Jun, et al. Effect of different nitrogen application on yield and quality of Nanjing 46[J]. Modern Agricultural Technology, 2020(2):17-18. (in Chinese)

(上接第269页)

- [14] MENG F, CHENG H, LI K, et al. Pruning filter in filter[J]. Advances in Neural Information Processing Systems, 2020, 33:17629-17640.
- [15] 方鹏, 郝宏运, 王红英, 等. 基于知识蒸馏的叠层笼养蛋鸡行为识别模型研究[J]. 农业机械学报, 2021, 52(10):300-306.
FANG Peng, HAO Hongyun, WANG Hongying, et al. Research on behavior recognition model of stacked cage laying hens based on knowledge distillation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(10):300-306. (in Chinese)
- [16] TAN K, WANG D. Compressing deep neural networks for efficient speech enhancement[C]//ICASSP 2021—2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2021: 8358-8362.
- [17] SANDLER M, HOWARD A, ZHU M, et al. Mobilenetv2: inverted residuals and linear bottlenecks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018:4510-4520.
- [18] ZHANG X, ZHOU X, LIN M, et al. Shufflenet: an extremely efficient convolutional neural network for mobile devices[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018:6848-6856.
- [19] HAN K, WANG Y, TIAN Q, et al. Ghostnet: more features from cheap operations[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020:1580-1589.
- [20] 张勤, 王家辉, 李彬, 等. 基于YOLOv3目标检测的秧苗列中心线提取方法[J]. 农业机械学报, 2020, 51(8):34-43.
ZHANG Qin, WANG Jiahui, LI Bin, et al. Extraction of seedling line based on YOLOv3 target detection[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(8):34-43. (in Chinese)
- [21] BOCHKOVSKIY A, WANG C Y, LIAO H, et al. Yolov4: optimal speed and accuracy of object detection[J]. arXiv preprint arXiv:2004.10934, 2020.
- [22] 朱红春, 李旭, 孟扬, 等. 基于Faster R-CNN网络的茶叶嫩芽检测[J]. 农业机械学报, 2022, 53(5):217-224.
ZHU Hongchun, LI Xu, MENG Yang, et al. Detection of tea buds based on Faster R-CNN network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(5):217-224. (in Chinese)
- [23] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]//Proceedings of the IEEE International Conference on Computer Vision, 2017: 2980-2988.
- [24] HOWARD A, SANDLER M, CHU G, et al. Searching for mobilenetv3[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019:1314-1324.
- [25] WANG Q, WU B, ZHU P, et al. Supplementary material for ECA-Net: efficient channel attention for deep convolutional neural networks[C]//Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, IEEE, 2020:13-19.
- [26] OTOVIĆ E, NJIRJAK M, JOZINOVIĆ D, et al. Intra-domain and cross-domain transfer learning for time series data—how transferable are the features? [J]. Knowledge-Based Systems, 2022, 239: 107976.
- [27] WOO S, PARK J, LEE J Y, et al. Cbam: convolutional block attention module[C]//Proceedings of the European Conference on Computer Vision (ECCV), 2018:3-19.
- [28] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021:13713-13722.