

doi: 10.7690/bgzdh.2024.02.018

基于 BERT+Bi-LSTM+CRF 的航天领域命名实体识别研究

夏旭东, 于荣欢

(航天工程大学复杂电子系统仿真重点实验室, 北京 101416)

摘要: 针对互联网开放数据中文本表述模糊、实体边界不清等问题, 构建航天语料库 Space-Corpus, 提出一种基于 BERT+Bi-LSTM+CRF 的航天领域命名实体识别模型。基于微调的多层双向 Transformer 编码器(bidirectional encoder representations from transformer, BERT)模型生成输入语料的向量化表示, 结合双向长短期记忆网络(bi-directional long short-term memory, Bi-LSTM)获取上下文特征, 通过条件随机场(conditional random field, CRF)层进行序列解码标注, 输出得分最高的预测标签。实验结果表明, 该模型在 Space-Corpus 语料库上较基于 BERT 模型、基于 BERT+Bi-LSTM 以及基于 CNN+Bi-LSTM+CRF 识别模型的准确率、召回率及 F_1 值均有提升。

关键词: 航天领域; 命名实体识别; BERT; 深度学习

中图分类号: TP391; V557 **文献标志码:** A

Research on Named Entity Recognition in Aerospace Field Based on BERT+Bi-LSTM+CRF

Xia Xudong, Yu Ronghuan

(Complex Electronic System Simulation Key Laboratory, Space Engineering University, Beijing 101416, China)

Abstract: Aiming at the problems of fuzzy text expression and unclear entity boundary in Internet open data, this paper constructs Space-Corpus, and proposes a named entity recognition model based on BERT + Bi-LSTM + CRF. The bidirectional encoder representations from transformer (BERT) model based on two-way training Transformer generates the vectorized representation of the input corpus, combines with bi-directional long short-term memory (Bi-LSTM) to obtain the context features, decodes and annotates the sequence through conditional random field (CRF), and outputs the predicted label with the highest score. Experimental results show that the proposed model outperforms the BERT model, BERT + Bi-LSTM model and CNN + Bi-LSTM + CRF model in terms of accuracy, recall and F_1 score on Space-Corpus corpus.

Keywords: aerospace field; named entity recognition; BERT; deep learning

0 引言

随着大数据、云计算、互联网的蓬勃发展, 网络上各类可利用的航天领域情报信息呈爆发式增长, 诸如各国航天机构官方网站、航天科普网站、航天新闻动态发布网站等, 都可成为获取开源航天情报的数据源。对开源航天情报信息进行深入挖掘与分析, 在更新与补充军用作战数据库、获取完善军事情报、了解网民舆论动态等方面具有重要意义。命名实体识别(named entity recognition, NER)是自然语言处理(natural language processing, NLP)技术研究的一个热点方向^[1], 其任务是从非结构化文本中自动识别出所需的实体, 并将其标记为预定义的类别^[2]; 因此, 航天领域命名实体识别可认为是从各类非结构化文本中自动识别出航天领域内特定类别的实体(如航天器、航天发射场、航天机构等实体), 是进行航天文本信息提取、指挥员语义理解、领域知识图谱构建等工作的关键性首要任务。

相比于通用领域, 航天领域因其领域特点在命名实体识别方面面临以下问题: 实体命名边界模糊。在航天领域经常存在一个实体的命名是由多个实体名组合而成的情况。例如“中国酒泉卫星发射中心”既可当作一个实体名, 又可以拆分为国别和机构 2 个实体; “地球静止轨道气象卫星”既可认为是一个实体, 又能够拆分为轨道环境名和卫星名 2 个实体名。此类问题为确定文本中实体的类别和数量带来了困扰, 因此, 明确实体边界是进行命名实体识别任务的重要工作。

实体名简称、别称多样。此类问题多出现在新闻报道类、航天科普类等文本中, 大量的代指、简称、别称等也为实体识别效果有负面影响。如“神舟十三号载人飞船”常被称为“神舟十三号”或“神十三”等, “玉兔号月球车”多简称为“玉兔号”, 甚至称为“玉兔”, 多样化的实体表述为实体识别任务增加了困难。

收稿日期: 2023-10-21; 修回日期: 2023-11-25

第一作者: 夏旭东(1997—), 男, 陕西人, 硕士。

公开语料库缺乏。不同于生物医药、法律等领域，航天领域因其领域独特性、专业性、保密性等原因，根据文献资料检索结果来看，目前未见面向航天领域公开的标注语料库、实体分类标准、标注策略等，而其他领域或通用标注语料模型无法迁移至航天领域，这为实体识别工作带来了阻碍。

为帮助识别指挥员指令、支持国防技术研究、辅助军用作战数据库的更新与完善，笔者结合航天领域专家意见及实际情况，提出面向航天领域的实体边界确定规则，基于互联网开源数据生成原始数据集，数据预处理后采用“BME0”标注策略对原始数据集进行标注得到航天语料库 Space-Corpus。提出一种基于 BERT+Bi-LSTM+CRF 的航天领域实体识别模型，利用 BERT 层获得航天词汇的向量化表示，将其输入到双向长短期记忆网络 (Bi-LSTM) 层中进行进一步上下文特征提取，通过条件随机场 CRF 层进行解码并得到最佳实体标签序列。

1 相关研究

目前，在航天领域内命名实体识别可供参考的资料比较匮乏，且尚无比较成熟的识别模型，但借鉴学者在其他军事领域内相关实体识别研究经验，可为构建航天领域实体识别模型提供一定程度的参考意义。

李健龙等^[3]通过无监督训练的方式得到了军事领域文本的字词特征分布表示，并采用 Bi-LSTM 递归神经网络模型进行军事领域命名实体识别，通过添加输入向量结合注意力机制对该模型进行改进，取得了较高的 F_1 值。张晓海等^[4]对作战指挥文本中的位置、部队、人员、物品以及数字进行识别，提出在 Bi-LSTM+CRF 模型的基础上，引入“自注意力”用于丰富文本局部特征，实验结果表明，在自建的包含作战文书、方案计划、新浪军事新闻等 300 余篇军事文本的语料测试集上军事命名实体取得了较好的识别准确率和 F_1 值。

随后张晓海等^[5]在收集的 100 篇未公开的作战文书中，通过分词和手工标注得到了作战文书语料库，提出基于 CNN+Bi-LSTM+CRF 模型的作战文书命名实体识别方法，实验结果证明，通过细分类的标注体系对特征表达具有较好的辅助作用。此外，王学锋等^[6]提出了基于 character+Bi-LSTM+CRF 的实体识别模型，并在构建的包含 30 余份学员训练用的联合作战演习想定文档、指挥所演练想定文档等文本组成的军事想定语料集上进行实验，结果表明

该方法识别效果优于传统方法。

尽管学者们在军事领域内自建的基于作战指令、作战文书、想定文档等语料库中实现了较可观的研究成果，但是这些语料库往往结构稳定，且实体密度较大、边界清晰、表述规范，而如何在面向实体内容分散、指代不清、语料库缺乏的互联网开源非结构化数据中实现航天领域的实体识别，仍是当前需要解决的重点问题。

2 航天领域语料库构建

为解决航天领域语料库缺乏这一问题，笔者基于互联网开源数据构建了面向航天领域的语料集 Space-Corpus，为实现航天领域命名实体识别奠定基础。如图 1 所示，语料库 Space-Corpus 的构建分为数据获取、数据处理和语料库构建 3 个步骤。

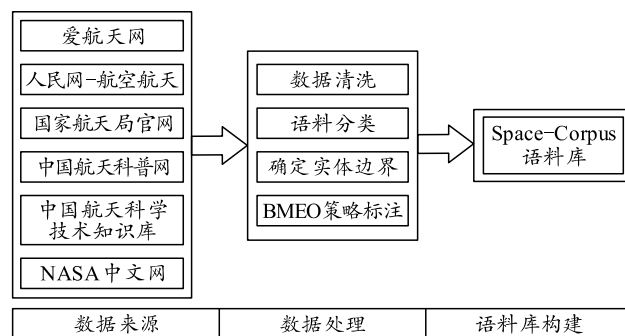


图 1 Space-Corpus 语料库构建过程

2.1 数据获取与清洗

笔者从爱航天网 (www.aihangtian.com)、人民网-航空航天 (www.scitech.people.com.cn/space)、中国航天科普网 (www.spacemore.com.cn)、国家航天局官网 (www.cnsa.gov.cn)、中国航天科学技术知识库 (www.spacespecial.com.cn)、NASA 中文网 (www.nasiachina.cn) 6 个网站中，爬虫得到的资讯、新闻、文章、评论等网页文本作为原始数据集。

对数据进行清洗，通过正则化等手段删除含有广告、链接、表达不完整以及不包含航天信息的无意义文本等数据，采用 UTF-8 编码格式以 TXT 文本形式存储，将标点符号“。”“！”“？”作为分句标志对文本进行句级划分。经统计数据预处理后共包含 1 073 份文本，9 863 个句子。

2.2 语料分类与边界明确

为充分利用获取的航天领域情报信息，根据实际情况，同时借鉴其他军事领域实体分类标准^[7]，笔者将爬取的数据分为人员名称、航天机构、国别、时间、相关实体、空间环境、功能及用途共 7 个类

别。同时，为解决航天领域内实体边界模糊、界定困难从而为后续实体标注与识别带来困扰等问题，笔者参考领域专家意见及其他领域方案^[8]，提出以下实体边界明确规则：

1) 国别与航天机构相连时，因航天机构的独有性，应将国别与机构分别标注。如“日本，鹿儿岛航天中心”“俄罗斯，东方航天发射场”。

2) 空间环境与相关实体相连时，若该实体具有明确指代，则应分别标注，否则一起标注为空间环境。如“地月转移轨道卫星”“地球静止轨道，风云二号卫星”。

3) 国别与相关实体相连时，若此实体为该国特有，则分别标注，否则一起标注为相关实体。如“美国，GPS 导航卫星”“俄罗斯运载火箭”。

4) 标注时间与相关实体时应按照尽可能准确原则标注。如“5 月 24 日”不应标注为“5 月，24 日”，“亚太 6D 通信卫星”不应标注为“亚太 6D，通信卫星”。

5) 数字、字母、短横线等字符与相关实体相连时，应当一起标注为实体。如“FY-2A 气象卫星”“GSAT-30 通讯卫星”等。

通过上述标注机制，能较好地解决航天领域实体标注过程中常见的边界不明确问题，为后续实体统计与文本标注提供基础。

2.3 文本标注与实体统计

基于前文对航天领域实体的分类及相关边界明确规则，笔者选择标注结构完整、过程清晰的 BMEO 标注体系。BMEO 标注是针对语料库中每个实体进行字级别的位置标注，其中：B 标注实体的起始字；M 表示实体的中间部分；E 表示实体的结尾字；O 表示非实体内容。为便捷高效地对大量文本进行字级别标注，笔者采用由新加坡科技设计大学 SUTD 研发的 LINUX 环境下的基于 Python 的文本标注工具—YEDDA^[9]，该软件由于开源且支持直接导入 TXT 文本而收到广泛应用，在 YEDDA 中，可根据用户需求，自定义需标注的实体类别并设置快捷键，因而能大幅提升标注效率。部分标注效果如图 2。

```

由 0
欧 B-Organization
洲 M-Organization
航 M-Organization
天 M-Organization
局 E-Organization
研 0
制 0

```

图 2 YEDDA 标注效果展示

经过数据清洗、语料分类、边界明确、BMEO 标注之后，原始数据集即转化为包含航天机构、航天人物、航天器、环境、时间、国别、功能及用途共 7 个类型的航天语料库 Space-Corpus，下面对 Space-Corpus 中 7 种类型的实体数量进行统计，统计结果如表 1 所示。

表 1 Space-Corpus 语料库实体统计

实体类型	实体标签	实体条数
环境	Environment	2 751
航天组织	Organization	2 478
时间	Time	4 289
航天器	Entity	7 760
航天人物	Person	2 765
国别	Nationality	1 952
功能及用途	Use	1 433

3 航天领域命名实体识别模型

3.1 模型总体架构

笔者提出一种基于 BERT+Bi-LSTM+CRF 的面向航天领域命名实体识别模型，该模型由 BERT 层、Bi-LSTM 层和 CRF 层 3 部分组成，其模型关系如图 3 所示。该模型输入为文本数据，输出是每个字符对应目标类型的标签序列，其中 BERT 预训练模型能够获取输入文本的语义编码信息；输出的向量进入 Bi-LSTM 层更进一步获取文本的上下文特征；结果再输入到 CRF 层中，结合序列标签间依赖关系对序列状态做出约束优化，最终获得全局最优序列。

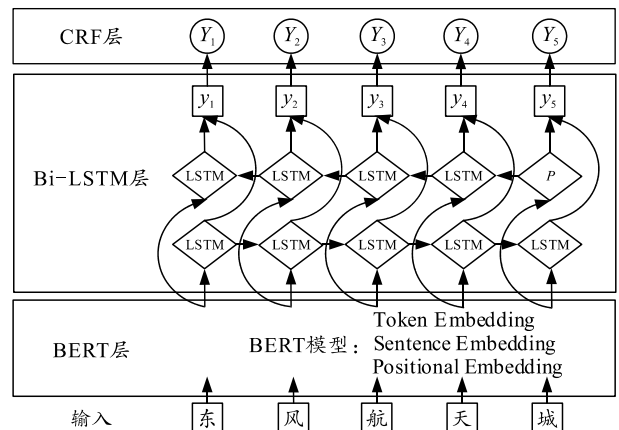


图 3 命名实体识别模型概述

3.2 BERT 层

将文本信息转化为相应的词向量嵌入到模型中，是进行命名实体识别的基础工作。目前比较流行的语言模型有 Word2Vec、GPT、Glove 等，但由于这些模型训练出的词向量属于静态向量，难以解决“一词多义”等情况^[10]；因此 2018 年，谷歌团队结合不同语言模型的优点，提出基于微调的多层

双向 Transformer 编码器 (BERT) 模型。

BERT 模型摒弃了传统的单向信息融合限制，开创性的采用了掩码语言模型 (masked language model, MLM) 和后句预测 (next sentence prediction, NSP) 2 个无监督预测任务进行预训练，其中 MLM 任务是将训练集中部分字符随机替换成 [mask]，通过训练用 [mask] 的上下文来预测 [mask] 的内容，从而提高预测精度。NSP 的任务是判断相邻 2 个句子之间的关系，从而确定句子间顺序的合理性。通过 MLM 和 NSP 2 个任务，能够使 BERT 模型充分理解文本中字符上下文关系以及句子级别的特征。

BERT 层中的核心内容是 Transformer^[11] 编码模型，该模型由编码器和解码器组成，用注意力机制代替传统的 RNN 模型。Transformer 模型能够将训练文本中的每个字映射为低维稠密度的向量和形式，该向量由字向量、句向量、位置向量组成，如图 4 所示。其中 [CLS] 标志符标记句子的开始，[SEP] 标志符标记句子的间隔或结束，字向量由查找字向量表获得，句向量用于表示句子中的语义信息，位置向量用于区分不同语句中不同位置的字的语义信息。

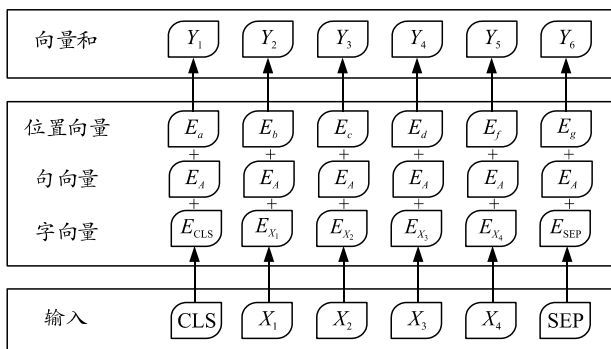


图 4 基于 BERT 的词向量生成

BERT 层处理后得到的 $Y=(Y_1, Y_2, \dots, Y_n)$ 经多层 Transformer 计算后得到的 $C=(C_1, C_2, \dots, C_n)$ 并输出到 Bi-LSTM 中进一步学习上下文特征，其结构如图 5 所示。

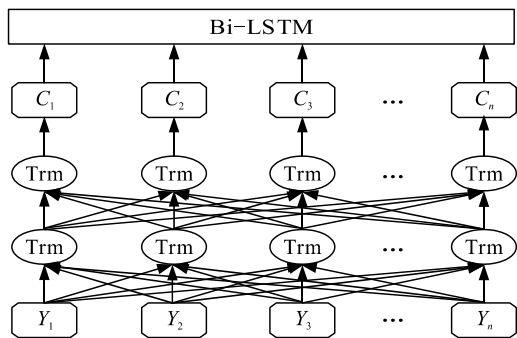


图 5 BERT 模型结构

3.3 Bi-LSTM 层

Bi-LSTM 是由 Hochreiter 等^[12] 于 1997 年提出的模型。Bi-LSTM 用于更加深入的学习上下文特征，从而获得更为全面的语义信息。长短期记忆网络 (long short-term memory, LSTM) 是对传统 RNN 进行改进的方案^[13]，通过引入记忆单元和门限机制来控制信息的遗忘、输入和输出，在学习到长距离依赖关系的同时有效解决了 RNN 网络中容易出现的梯度消失和梯度爆炸现象。LSTM 单元结构如图 6 所示。

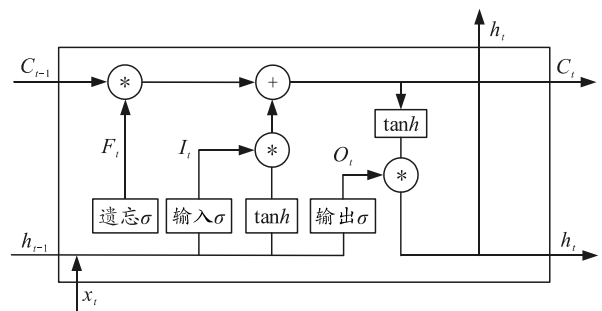


图 6 LSTM 单元结构

图中，输入信息通过遗忘门 F 、输入门 I 、输出门 O 三层结构来进行信息处理，其中遗忘门用于判断信息中哪些部分需要被丢弃；输入门用于判断哪些信息可更新到下一个单元结构中；输出门用于判断哪部分信息可以输出。在 t 时刻 LSTM 的单元状态可由式(1)–(5)得到：

$$F_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f); \quad (1)$$

$$I_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i); \quad (2)$$

$$O_t = \sigma(W_o \times [h_{t-1}, x_t] + b_o); \quad (3)$$

$$C_t = F_t * C_{t-1} + I_t * \tanh(W_c \times [h_{t-1}, x_t] + b_c). \quad (4)$$

式中： F 、 I 、 O 为输入门、输出门和遗忘门； W 为权重矩阵； b 为偏置矩阵； h_{t-1} 为 $t-1$ 时刻的输出； x_t 为 t 时刻 LSTM 的输入； C_t 为 t 时刻 LSTM 的状态； σ 和 \tanh 为激励函数； O_t 为生成矩阵。

则 t 时刻 LSTM 的输出可表示为：

$$h_t = O_t * \tanh(C_t). \quad (5)$$

LSTM 的结构使其能够获得前文的信息，而对于后文信息却不能利用，但同时获取前后文双向信息是尤为关键的；因此，笔者通过首尾串联的方式将前向、后向 2 组 LSTM 拼接得到 Bi-LSTM 模型来获得前后文的深层信息。

3.4 CRF 层

条件随机场 (CRF) 层是较为流行的用于计算可

能性得分最高的命名实体类别^[14]。CRF 代替传统的 softmax 作为神经网络的输出层，其强大的序列建模能力使其能够通过编码过程中的约束条件进行学习，从而保证最终的预测结果具有较高的准确性^[15]。

CRF 算法能够利用相邻标注结果的关系对全文中的最优标记序列进行输出，其基本算法如下。

假定对于长度为 n 的语句，输出层的得分矩阵为 $P \in R^{n \times k}$ ，其中 k 为标签种类，矩阵元素 P_{ij} 为第 i 个词在第 j 个标签下的得分。则对于输入句子 $X=(X_1, X_2, \dots, X_n)$ ，输出标签序列 $Y=(Y_1, Y_2, \dots, Y_n)$ 的得分为：

$$S(X, Y) = \sum_{i=0}^n B_{y_i, y_{i+1}} + \sum_{i=1}^n P_{i, y_i} \quad (6)$$

式中 B 为 Bi-LSTM 的输出得分矩阵。

对全部可能性的序列路径进行归一化，即可得到关于输出序列 Y 的概率分布为：

$$P(Y|S) = e^{S(x,y)} / \sum_{y \in Y_x} e^{S(x,y)} \quad (7)$$

为使得以上概率达到最大，先求解关于正确标签的 Y^* 的对数似然函数：

$$\log(p(Y|S)) = S(X, Y) - \log(\sum_{y \in Y_x} e^{S(x,y)}) \quad (8)$$

式中 y 为所有符合正确标注规则的序列。训练时通过最大化对数似然函数得到整体概率最大的输出序列：

$$Y^* = \operatorname{argmax} S(X, \tilde{Y}) \quad (9)$$

通过 CRF 层对所有 Bi-LSTM 层的输出进行有条件的约束，再从 CRF 层中选取得分最高的序列进行最终输出，能够有效降低错误预测序列的概率。

4 实验及结果分析

为验证笔者提出的基于 BERT+Bi-LSTM+CRF 的航天领域命名实体识别模型的准确率与可靠性，笔者在航天领域语料库 Space-Corpus 上，对该模型进行测试实验：首先分别测试语料库中各个类型实体的识别准确率并对识别结果进行分析；并将模型与主流的基于 BERT、BERT+Bi-LSTM、以及 CNN+Bi-LSTM+CRF 的命名实体识别模型进行比较；最后通过验证不同规模的语料库对模型训练效果的影响。

4.1 实验设置

实验环境：

计算机：Lenovo

操作系统：Windows10 家庭中文版

GPU：NVIDIA GeForce RTX 2060

深度学习框架：Pytorch'1.11.0+cu113'

Python：3.10.4

神经网络超参数设置如表 2 所示。

表 2 神经网络超参数设置

名称	参数值
dropout	0.3
LSTM_size	128
batch_size	32
Learning_rate	3e-5
max_seq_len	100

4.2 评价指标

实验采用实体识别领域中 3 个通用的评测指标作为评价标准，即准确率 (P)、召回率 (R) 和 F_1 值 (F -score)，其中 F_1 值能够体现整体的测试效果，具体的计算公式如下：

$$P = T_p / (T_p + F_p) \times 100\% \quad (10)$$

$$R = T_p / (T_p + F_n) \times 100\% \quad (11)$$

$$F = (2 \times P \times R) / (P + R) \times 100\% \quad (12)$$

式中： T_p 为正确识别的实体个数； F_p 为识别错误的实体个数； F_n 为未识别出的实体个数。

4.3 实验结果及分析

实验 1：将航天领域语料库 Space-Corpus 2 次分层抽取 15% 分别作为验证集和测试集，剩余 70% 作为训练集，各标注实体在训练集、验证集和测试集上均匀分布。设置模型 epoch 最大值为 50。表 3 为各标注实体类型在本文中所提的命名实体识别模型上的实验结果。

表 3 实验结果 1

实体类型	P	R	F_1
Environment	0.971 3	0.857 1	0.910 5
Organization	0.900 5	0.823 0	0.860 0
Time	0.961 5	0.910 5	0.935 3
Entity	0.897 2	0.885 4	0.891 3
Person	0.980 1	0.920 3	0.949 3
Nationality	0.863 3	0.872 9	0.868 1
Use	0.796 2	0.825 1	0.810 4
Weighted average	0.912 6	0.885 2	0.899 0

由上表可见，识别效果较好的实体类型主要有“Time”“Person”“Environment”等，经分析，原因是这些实体通常特征明显且往往以相对规范的格式出现；而同一模型在各个实体类型上的识别效果会有较大的高低差异，例如对于“Use”类型，模型的识别 F_1 值只有 81.04%，原因是介绍实体或机

构,尤其是复杂实体或大型机构的功能用途时往往难以用清楚的语句精简表述,例如语句“日本宇宙航空研究开发机构,主要工作包括研究、开发和发射人造卫星,小行星探测以及未来可能的登月工程”,在标注时就容易出现标签重复和冗杂等问题;同时对于“Nationality”类型文本,模型识别 F_1 值只有 86.81%,原因是在航天领域发展成果丰富的国别样本数量较少,模型学习不够充分。

实验 2: 将本文中所提模型与军事领域常用识别模型的识别效果进行对比。第 1 组对照实验为:基于 BERT 的命名实体识别模型,第 2 组对照实验为 BERT+Bi-LSTM 的命名实体识别模型,第 3 组对照实验为基于 CNN+Bi-LSTM+CRF 的命名实体识别模型。

将笔者所提模型与前 2 组实验模型进行对照,能够获得添加 Bi-LSTM 层与 CRF 层带来的识别效果的提升;与第 3 组实验模型对照能够获得 BERT 层相对于 CNN 层进行的识别效果提升。表 4 为对比实验结果。

表 4 实验结果 2

识别模型	P	R	F_1
基于 BERT	0.855 1	0.819 7	0.837 0
基于 BERT+Bi-LSTM	0.887 2	0.831 6	0.858 5
基于 CNN+Bi-LSTM+CRF	0.898 3	0.853 1	0.875 1
基于 BERT+Bi-LSTM+CRF	0.912 6	0.885 2	0.899 0

实验结果表明,Bi-LSTM 层的加入由于对输入的前后文特征双向提取,能够学习到更全面的语义信息,从而在基于 BERT 的识别模型基础上 F_1 值约提升了 2%,而 CRF 层的加入使得对预测标签之间的约束更加明确,能够准确输出预测标签的全局最优序列,因而 F_1 值大约提升了 4%;BERT 层相比于 CNN 网络 F_1 值提升了约 2.5%,可能原因是 BERT 层能够有效控制梯度的消失或梯度爆炸,从而对识别效果有所提升。

实验 3: 测试语料规模对识别效果的影响。将航天领域语料库 Space-Corpus 划分为 4 个大小相似的子库,从第 1 个子库开始实验,每次添加一个子库,分 3 次添加完成。分别记录每次结果的 P 、 R 、 F_1 值,结果如图 7 所示。

图中可以看出, P 、 R 、 F_1 值随着语料库规模的增大而提升,说明训练集越大、学习内容越多,模型的识别效果越好,同时也证明一个好的基于深度学习的命名实体识别模型需要大量的标注语料进行

训练才能训练成功。




图 7 实验结果 3

5 结束语

通过基于 Space-Corpus 语料库的实验证明:笔者所提模型比基于 BERT 的识别模型 F_1 值提升 6.2%,比基于 BERT+Bi-LSTM 的识别模型 F_1 值提升了 4.1%,相较于 CNN+Bi-LSTM+CRF 模型, F_1 值提升了 2.5%。

当前 Space-Corpus 语料库的数据大多来自于航天类官方或科普类网站,未来应对包括微博、新浪等其他社交媒体上的数据进行扩充,同时在算法上考虑加入迁移学习,将训练好的模型在航天领域其他范围内进行应用,从而节省训练时间。

参考文献:

- [1] 刘凯,张宏军,陈飞琼.基于领域适应嵌入的军事命名实体识别[J].计算机科学,2022,49(1):292-297.
- [2] 何阳宇,晏雷,易绵竹,等.融合 CRF 与规则的老挝语军事领域命名实体识别方法[J].计算机工程,2020(8):297-304.
- [3] 李健龙,王盼卿,韩琪羽.基于双向 LSTM 的军事命名实体识别[J].计算机工程与科学,2019,41(4):713-718.
- [4] 张晓海,操新文,张敏.基于自注意力机制的军事命名实体识别[J].指挥控制与仿真,2019,41(6):29-33.
- [5] 张晓海,操新文,高源.基于深度学习的作战文书命名实体识别[J].指挥控制与仿真,2019,41(4):22-26.
- [6] 王学锋,杨若鹏,朱巍.基于深度学习的军事命名实体识别方法[J].装甲兵工程学院学报,2018,32(4):94-98.
- [7] 张祺,李成军,刘敬蜀.基于 BERT_IDCNN_CRF 的军事领域命名实体识别研究[J].航天电子对抗,2021,37(5):56-60.
- [8] 尹学振,赵慧,赵俊保,等.多神经网络协作的军事领域命名实体识别[J].清华大学学报(自然科学版),2020,60(8):648-655.