

民航突发事件实体识别方法研究

王红 李浩飞* 邸帅

(中国民航大学计算机科学与技术学院 天津 300300)

摘要 针对民航突发事件实体自动获取的问题,提出一种将双向长短期记忆网络(BiLSTM)与条件随机场(CRF)结合的民航突发事件实体识别方法。利用领域词典对民航突发事件实体进行自动标注,并将已标注的数据转化为分布式字符向量;采用 BiLSTM 模型获取序列文本的上下文特征;通过 CRF 模型获得序列标注结果。实验结果表明,与传统的 CRF 方法相比,该方法的 F 值有明显的提升,有效解决了传统方法在识别民航突发事件文本信息中包含复合实体或混合实体方面效率低且大量使用人工定义特征模板的问题,为民航突发事件知识图谱的自动构建提供了更好的方法支撑。

关键词 民航突发事件 条件随机场 长短期记忆神经网络 实体识别 知识图谱

中图分类号 TP391 **文献标志码** A **DOI**:10.3969/j.issn.1000-386x.2020.03.028

ENTITY RECOGNITION METHOD OF CIVIL AVIATION EMERGENCY

Wang Hong Li Hao-fei* Di Shuai

(School of Computer Science and Technology, Civil Aviation University of China, Tianjin 300300, China)

Abstract Aiming at the problem of automatic acquisition of civil aviation emergency entities, this paper proposes a method of civil aviation emergency entity recognition based on the combination of BiLSTM and CRF. We used the domain dictionary to automatically label the civil aviation emergency entities, and transformed the labeled data into distributed character vectors. BiLSTM model was adopted to get the context features of sequence text, and CRF model was used to get the sequence labeled results. The experimental results show that compared with the traditional CRF method, the F-value of this method is significantly improved, which effectively solves the problem that the traditional method is inefficient in identifying composite or mixed entities in the text information of civil aviation emergencies and uses a large number of manually defined feature templates. And it provides a better method support for the automatic construction of civil aviation emergencies knowledge graph.

Keywords Civil aviation emergency Conditional random field BiLSTM Entity recognition Knowledge graph

0 引言

知识图谱^[1]是知识表示的重要工具,国内外学者针对知识图谱构建方法及其应用方面做了大量的研究^[2-7],利用知识图谱可以有效地实现领域知识的表达、检索与推理。近年来民航突发事件呈多元化趋势,包括大面积航班延误、航空器危险接近、航空器坠毁等。

研究民航突发事件知识图谱构建的关键问题对于

提升民航突发事件应急处置能力具有重要意义。民航突发事件知识图谱构建的核心内容包括实体识别和实体关系抽取等,其中民航突发事件实体识别是构建民航突发事件知识图谱的基础。

民航突发事件实体识别^[8]是一种特定领域的实体识别,主要任务是从非结构化民航突发事件文本数据中识别出发事时间、事发地点、事发原因、事发结果、航空公司、飞机型号、注册号等多种不同类型实体,目的是对民航突发事件领域中专业词汇进行确认和分类,从而实现非结构民航突发事件数据结构化,并以结

果化形式进行知识表示。目前,民航突发事件实体识别主要有两个难点:1) 由于领域的特殊性,基于传统的统计机器学习的实体识别往往依赖领域语言学知识且需要大量人工定义特征模板。2) 该领域的实体长度一般较长,存在大量复合或混合型实体,例如复合起飞地名(美国南卡罗来纳州哥伦比亚大都会机场)、航空公司名等,或混合型实体如飞机型号(萨博 A340A 型飞机)等。实体的边界模糊、结构复杂,实体长度较长且内部相关关系较为密切,传统的网络结构难以学习此类依赖关系。

目前实体识别的研究主要集中在医疗^[9-10]、社交媒体^[11-12]、农业^[13]、渔业^[14-15]、动物卫生^[16]、军事^[17]、海事^[18]等领域。实体识别方法主要分为三类:基于规则的方法、基于统计机器学习的方法和基于深度学习的方法。其中:1) 基于规则的方法通常依赖于启发式和手工制作的规则来识别实体,通过语言学者和领域专家手工制定的大量规则通常会导致相对较高的系统工程成本,且领域移植性相对较差。2) 基于统计机器学习方法将实体识别视为序列标记问题,其目标是找到给定输入句子的最佳标签序列来识别实体。典型的方法是隐马尔可夫模型(Hidden Markov Model, HMM)^[19]、支持向量机(Support Vector Machine, SVM)^[20]和条件随机场(Condition Random Fields, CRF)^[21]。但此类模型识别实体的准确率往往依赖于人工预先定义特征集的数量及质量。3) 基于深度学习的方法在词性标注、关键词提取、命名实体识别(Named Entity Recognition, NER)等众多自然语言处理子任务均有突破性进展。尤其是基于循环神经网络(Recurrent Neural Network, RNN)方法,可以很好地处理 NER 问题,它不仅优于传统的统计机器学习方法,而且避免大量使用人工定义特征模板,然而 RNN 无法有效解决长距离依赖以及在反向传播时存在的梯度消失或爆炸问题。针对此问题, Hochreiter 等^[22]提出一种利用门限机制对历史信息进行过滤的 LSTM 模型, Hammerton^[23]首次将 LSTM 模型运用到 NER。然而 LSTM 只捕获了文本的上文信息,对于 NER 任务,下文信息也同样重要。冯艳红等^[24]将 BiLSTM 模型^[25]用于 NER 任务,在多个中文数据集上取得不错的效果。Peng 等^[26]首次构建基于微博信息的中文社交媒体语料库,先利用 LSTM 模型提取文本特征,再通过 CRF 进行分类,最终提高了社交媒体实体识别的性能。

为此,本文将 BiLSTM 与 CRF 相结合,提出了一种基于 BiLSTM-CRF(Bidirectional Long-Short Term Memory-Conditional Random Filed)的民航突发事件实体识别方法,旨在解决非结构化民航突发事件文本信息中实

体的自动获取问题。

1 研究思路

民航突发事件文本集合 $T = \{i_1, i_2, \dots, i_n\} \subseteq I$, 在 i_i 中存在实体集合 $F = \{f_1, f_2, \dots, f_n\}$, 其中 f_i 是民航突发事件文本 I 中的某个实体, 每个 f_i 都唯一映射实体类型集合 $K = \{k_1, k_2, \dots, k_n\}$ 中的实体类型 k_i 。我们的目的是将民航突发事件文本集合 $I = \{i_1, i_2, \dots, i_n\}$, 通过 BiLSTM-CRF 模型抽取每个文本 i_i 中的所有实体集合 $F = \{f_1, f_2, \dots, f_n\}$, 并分别给每个实体 f_i 标记实体类型 k_i 。民航突发事件实体识别方法研究思路如图 1 所示。

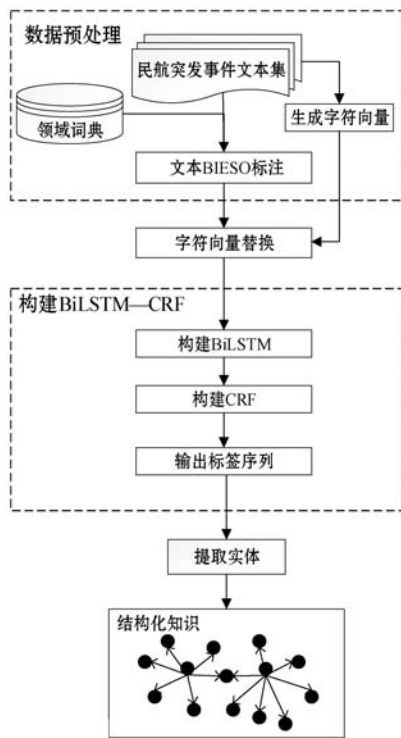


图1 民航突发事件实体识别过程

(1) 数据预处理: 对民航突发事件文本进行标注, 同时对其进行字符向量训练。

(2) 构建 BiLSTM-CRF 模型: 将标注好的数据通过查找预先训练的字符向量表替换为字符向量序列, 输入到 BiLSTM 模型中, 获取序列化文本的上下文特征, 再通过 CRF 模型获取序列标注结果提取出民航突发事件实体, 并将民航突发事件知识以 < 头实体, 关系, 尾实体 > 三元组的形式储存在图数据库中形成结构化知识体系。

2 数据预处理

将民航突发事件文本进行数据去重, 然后利用 Word2vec 对数据进行字符向量训练, 生成字符向量

表,同时采用自动标注方式对民航突发事件实体进行标注。由于分词的质量取决于词典,因此首先构建领域词典,然后通过匹配领域词典中的航空公司名库、航班号库、起飞地名库等相关实体库的方式,采用 Python 编程语言中的 Jieba 自定义词典分词模块进行分词与实体标注。

民航突发事件实体识别任务可以视为序列标注任务。为更加清楚地划分实体边界,采用 BIEO (Begin, Inside, End, Outside) 标签方案对民航突发事件语料进行标注。B 表示民航突发事件实体的第一个字符, I 表示实体的内部字符, E 表示实体的结尾字符, O 表示非实体的字符(如表 1 所示)。给定一个民航突发事件文本中含有 n 个字符的句子 $S = \{c_1, c_2, \dots, c_n\}$, 采用上述标注方法标记句子 S 的每个字符 c_i 。例如,“……QF-8 航班……”的标签序列(如表 2 所示)。

表 1 实体标注方法

实体类型	实体开始	实体内部	实体结尾
事发时间	B-DATE	I-DATE	E-DATE
航空公司	B-ARIL	I-ARIL	E-ARIL
飞机型号	B-FTYPE	I-FTYPE	E-FTYPE
注册号	B-REG	I-REG	E-REG
航班号	B-FNUM	I-FNUM	E-FNUM
起飞地	B-ORIG	I-ORIG	E-ORIG
目的地	B-DEST	I-DEST	E-DEST
乘客人数	B-PSG	I-PSG	E-PSG
机组人数	B-CREW	I-CREW	E-CREW
事发地点	B-LOC	I-LOC	E-LOC
伤亡人数	B-CASU	I-CASU	E-CASU
事发原因	B-REA	I-REA	E-REA
事发结果	B-RES	I-RES	E-RES
非实体类型	O	O	O

表 2 字符序列标注实例

字符序列	Q	F	-	8	航	班
标签序列	B-FNUM	I-FNUM	I-FNUM	I-FNUM	I-FNUM	E-DEST
实体类型	航班号					

3 BiLSTM—CRF 模型构建

根据图 1 的研究思路和民航突发事件实体结构特点,采用字符向量作为 BiLSTM 的输入,并利用 BiLSTM 来捕捉分布表示中实体的过去和未来的上下文信息。由于 BiLSTM 忽略了标签的等价性质,因此,我们结合 CRF 序列模型来确保标记的一致性,提高输出

的准确率。该模型主要分为以下 3 层,其模型如图 2 所示。

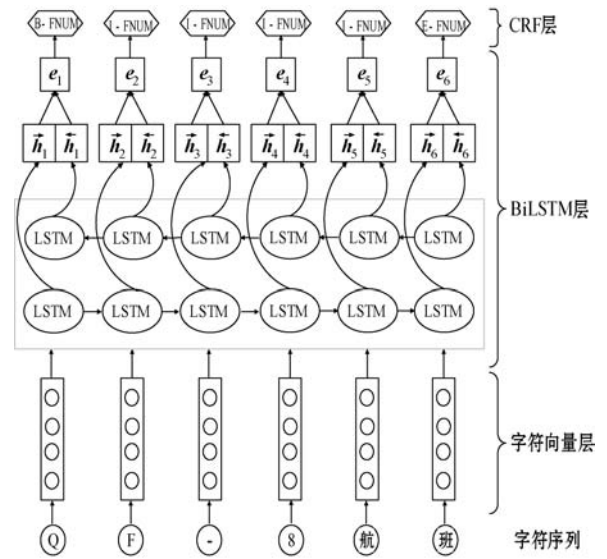


图 2 BiLSTM-CRF 民航突发事件实体识别模型

3.1 字符向量表示层

在编码阶段,采用字符向量的表示方法。字符向量化一般有两种表示方法:one-hot 表示和分布式表示。基于分布式表示的字符向量不仅避免维度灾难,而且也学习到民航突发事件文本中字符之间的语义特征,故选择基于分布式表示的字符向量作为 BiLSTM 层的输入。

利用 Word2vec 的 CBOW 模型或 Skip-gram 模型进行训练可得到分布式表示,而 CBOW 的训练效率高于 Skip-gram,故本文将民航突发事件语料通过 CBOW 模型进行训练,其生成的字符向量表共包含 3 496 个汉语字符、英文字符和特殊字符(如数字,标点符号等)以及它们的分布式数字向量表示。字符向量矩阵大小为 $3\ 496 \times 100$,具体步骤如下:

(1) 以句子为单位将文本序列进行分隔,含有 n 个字符的句子则定义为 $S = \{c_1, c_2, \dots, c_n\}$ 。

(2) 文本序列的每个字符 c_i 都映射到字符向量矩阵 M 中的一个字符向量 x_i 。

$$x_i = M^d v^i \quad M \in \mathbf{R}^{d \times |V|} \quad (1)$$

式中: d 表示字符向量的维度; V 表示语料字典的总字数,字典汉语字符、英文字符和特殊字符组成; v_i 的维度为 V ,其元素取值规则为第 i 行的值取 1,其他行的值取 0。

3.2 BiLSTM 层

3.2.1 LSTM

RNN 在处理 NER 问题取得不错的效果。把序列向量 $X = \{x_1, x_2, \dots, x_n\}$ 作为 RNN 的输入,将返回另一个序列向量 $H = \{h_1, h_2, \dots, h_n\}$,该序列向量 H 表示学习到的在输入中每个步骤的序列信息。从理论上

讲,RNN 可以处理长时依赖问题,但在实践中效果很差,只学习到序列数据最近输入的信息。LSTM 相对与传统的 RNN 有着更为复杂记忆单元,在一定程度上大幅减小了梯度爆炸或梯度消失的影响,并且已经被证明可以捕获到长时依赖性。一个 LSTM 单元由输入门、输出门、遗忘门以及一个记忆单元共同构成,LSTM 模型的一个单元更新的过程见图 3。

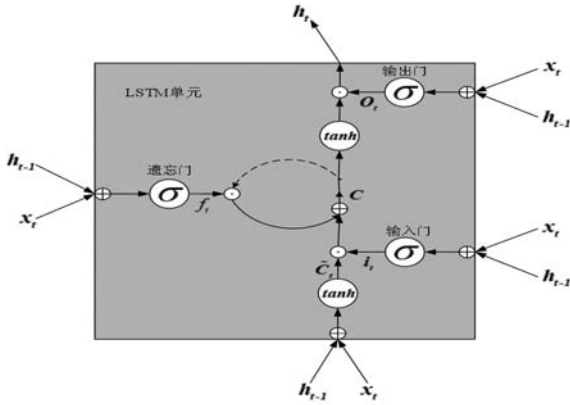


图3 LSTM 单元结构图

其具体计算公式定义如下所示:

$$\tilde{C}_t = \tanh(W_c \cdot (h_{t-1}, x_t) + b_c) \quad (2)$$

$$i_t = \sigma(W_i \cdot (h_{t-1}, x_t) + b_i) \quad (3)$$

$$f_t = \sigma(W_f \cdot (h_{t-1}, x_t) + b_f) \quad (4)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (5)$$

$$o_t = \sigma(W_o \cdot (h_{t-1}, x_t) + b_o) \quad (6)$$

$$h_t = o_t \odot \tanh(C_t) \quad (7)$$

式中: \odot 为向量点乘操作;元素 σ 代表激活函数 Sigmoid 函数; x_t 为 LSTM 层时间在第 t 步的输入向量(即字符向量); h_{t-1} 是 LSTM 层的隐藏层状态向量(也称输出向量),其存储前 $t-1$ 步所有有用的时序信息; W_i 、 W_f 、 W_c 、 W_o 表示隐藏层向量 h_{t-1} 的权重矩阵, b_i 、 b_f 、 b_c 、 b_o 表示偏差向量。

3.2.2 BiLSTM

针对序列标注任务,遍历过去和未来的上下文对解决实体识别问题是有帮助的。然而,LSTM 的隐藏状态仅从过去获取信息,对未来一无所知。因此,我们采用 BiLSTM 来更好解决民航突发事件实体识别这一问题。基本思想是将每个序列向前和向后呈现给两个单独的隐藏状态,以分别捕获序列数据的过去和未来的信息,最后将两个隐藏状态连接起来以形成最终输出。

图 4 是 BiLSTM 按时间展开的结构图。设输入的句子 $S = \{c_1, c_2, \dots, c_n\}$ 转化为字符向量 $X = \{x_1, x_2, \dots, x_n\}$,将字符向量 X 输入到 BiLSTM,将会输出与之对应的正向 LSTM 隐藏层状态向量 $\vec{h} = (\vec{h}_1, \vec{h}_2, \dots, \vec{h}_n)$ 和反向 LSTM 隐藏层状态向量 $\overleftarrow{h} = (\overleftarrow{h}_1, \overleftarrow{h}_2, \dots, \overleftarrow{h}_n)$ 。对

于句子 S 中任意一个字符 c_t 的 BiLSTM 隐藏层状态向量 h_t 由正向和反向对应位置的 LSTM 隐藏层向量 \vec{h}_t 和 \overleftarrow{h}_t 拼接生成,即 $h_t = [\vec{h}_t; \overleftarrow{h}_t]$,其中 \vec{h}_t 表示捕获正向传播上下文信息, \overleftarrow{h}_t 表示捕获反向传播上下文信息, h_t 表示包含双向上下文信息。

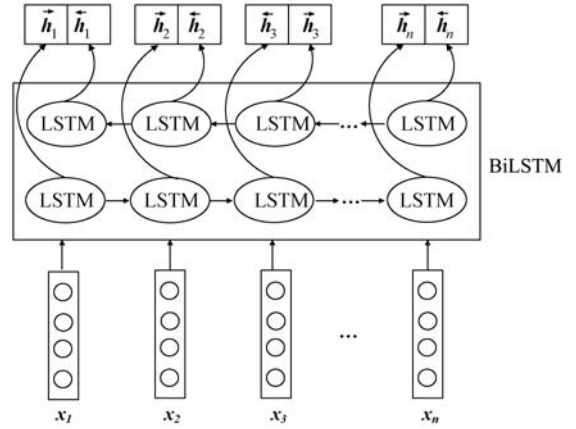


图4 BiLSTM 结构图

然后在 BiLSTM 的顶部使用 \tanh 激活函数来预测字符的每个可能的标签的置信度分数。

$$e_t = \tanh(W_e h_t) \quad (8)$$

式中: W_e 为隐藏层的权重矩阵。

3.3 CRF 输出层

对于序列标记任务,考虑邻域中标签之间的相关性并联合解码对预测输入句子的最佳标签链是有益的。在民航突发事件实体识别中,I-ARIL 不能跟随 I-DATE。因此,本文模型使用 CRF 和 BiLSTM 共同模拟标记序列。

记 P 为 BiLSTM 层输出的得分矩阵,其中 P 的大小为 $n \times k$, n 为输入序列的长度, k 为标签集合的大小,则 P 的第 t 列是由式(8)得出的向量 e_t ,那么 $P_{i,j}$ 表示输入文本序列中第 i 个字符对应第 j 个标签的分数。我们引入了转换矩阵 A ,其中 $A_{i,j}$ 表示连续字符由标签 i 到标记 j 的转换概率。这个转换矩阵将被训练为模型的参数。对于长度为 n 的句子 $X = \{x_1, x_2, \dots, x_n\}$ 的标签序列 $y = \{y_1, y_2, \dots, y_n\}$,其分数为:

$$S(X, y) = \sum_{i=1}^n (A_{y_{i-1}, y_i} + P_{i, y_i}) \quad (9)$$

使用 Softmax 函数计算条件概率 $p(y|X)$:

$$p(y|X) = \frac{e^{S(X, y)}}{\sum_{\tilde{y} \in Y_X} e^{S(X, \tilde{y})}} \quad (10)$$

式中: Y_X 是针对输入字符序列 X 所有可能标签序列。我们使用最大条件似然估计来训练模型:

$$\log p(y|X) - \log \sum_{\tilde{y} \in Y_X} e^{S(X, \tilde{y})} \quad (11)$$

训练结束后,在预测标签时,寻找得分最高的标签

序列作为输出结果,即:

$$\arg \max_{\hat{y} \in Y_X} S(X, y) \quad (12)$$

4 实验与结果分析

4.1 数据集与评价指标

所使用的语料主要来自中国民用航空安全信息系统^[27]发布的世界航空安全事故调查跟踪报告等文本数据 900 余个。按照第 2 节数据标注方法标注实体,建立了一个基于民航突发事件实体识别的语料库,作为本文实验的实体识别数据集,如表 3 所示。

表 3 语料统计信息

数据集	训练数据	测试数据
句子总数	8 064	2 312
字符总数	138 238	41 471
实体总数	6 623	1 674

本文采用 NER 中常用的正确率 (precision)、召回率 (recall) 和 F 值作为模型性能评价指标,计算公式如下:

$$precision = \frac{out_right}{out} \quad (13)$$

$$recall = \frac{out_right}{all} \quad (14)$$

$$F_score = \frac{2 \times precision \times recall}{precision + recall} \quad (15)$$

式中: *out_right* 表示正确预测的实体个数; *out* 表示所有预测的实体个数; *all* 表示测试集中所有的实体个数。在准确率相同的情况下,召回率越高越好;在召回率相同的情况下,准确率越高越好。

4.2 实验环境与模型参数设置

本文实验环境及其配置如表 4 所示。

表 4 实验环境配置

实验环境	环境配置
操作系统	Windows 10
处理器	Intel(R) Core(TM) i7 - 7700
内存	16 GB
编程语言	Python 3.6
深度学习框架	Tensorflow 1.10.0

采用 Adam 算法来优化模型参数,利用 Dropout 机制消除 BiLSTM 模型过拟合的影响,并使用梯度裁剪技术避免梯度爆炸。模型参数设置如表 5 所示。

表 5 参数设置

参数	值
字符向量维度	100
LSTM 隐藏层节点数	100
Batch_size	60
Dropout 参数	0.5
学习率	0.001
梯度裁剪阈值	5

4.3 实验结果

选取 4.1 节民航突发事件数据集的训练集在本文提取的模型上进行训练,再采用测试集对训练后的模型进行评测。对民航突发事件的事发时间、航空公司、飞机型号、注册号、航班号、起飞地、目的地、乘客人数、机组人数、事发地点、伤亡人数、事发原因和事发结果共 13 种实体类型的实体进行识别,具体结果如表 6 所示。

表 6 民航突发事件实体识别实验结果 %

实体类型	准确率/%	召回率/%	F 值/%
事发时间	97.56	100.00	98.77
航空公司	97.67	87.50	92.31
飞机型号	91.92	96.38	94.10
注册号	91.89	94.44	93.15
航班号	87.83	91.60	89.68
起飞地	95.12	88.64	91.77
目的地	84.98	79.59	82.20
乘客人数	94.59	94.59	94.59
机组人数	93.27	95.68	94.46
事发地点	83.89	80.16	81.98
伤亡人数	84.44	84.44	84.44
事发原因	88.58	85.63	87.08
事发结果	92.56	93.27	92.91
总体指标	91.57	90.10	90.83

从表 6 可以看出,事发时间的实体识别 F 值最高,乘客人数和机组人数的实体 F 值相对较高,主要是由于事发时间、乘客人数和机组人数实体类型为日期型数据和数值型数据,其表达形式相对固定且实体语义较为简单。事发地点、目的地实体准确率相对较低主要是由于字符数量相对较长且其实体语义较为复杂。而在民航突发事件数据集中伤亡人数的实体分布低于其他实体,因此其 F 值相对较低。

在提取相应实体之后,将民航突发事件知识以三元组形式加载到 Neo4j 图数据库进行知识的整合与存储。图 5 为结构化民航突发事件知识局部效果,其中:

实线椭圆表示头实体(由事发时间实体和航班号实体拼接而成作为事件的唯一标识实体);虚线椭圆表示尾实体;实线箭头代表头实体与尾实体的关系(以尾实体的实体类型名称来指代实体间关系)。

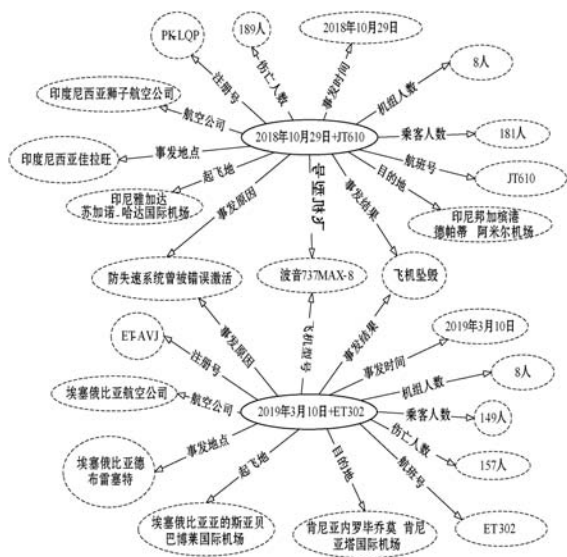


图 5 结构化民航突发事件知识局部效果

4.4 对比分析

为体现 BiLSTM-CRF 在 F 值上的优势,本文在民航突发事件数据集上,分别对 CRF、LSTM、BiLSTM、LSTM-CRF 和 BiLSTM-CRF 这 5 种模型进行对比实验,其中 CRF 模型使用原子特征、组合特征、标记特征相结合的特征模板^[28],以准确率、召回率和 F 值对各模型评测,实验结果如表 7 所示。

表 7 民航突发事件数据集各模型实体识别实验对比 %

模型	准确率	召回率	F 值
CRF	83.68	84.76	84.22
LSTM	85.48	86.62	86.05
BiLSTM	86.56	87.23	86.89
LSTM-CRF	89.64	88.38	89.01
BiLSTM-CRF	91.57	90.10	90.83

从表 7 可知,LSTM 模型较 CRF 模型的 F 值高出 1.83%,这表明基于深度学习网络模型相对于基于传统机器学习方法能够更好地利用句子级的语义特征,取得更好的实体识别效果。同时,BiLSTM 模型要略好于 LSTM,这是因为 LSTM 模型仅能捕获到实体的过去上下文信息,而 BiLSTM 捕获到实体的过去和未来的信息,弥补了 LSTM 模型的劣势。将 BiLSTM 模型与 CRF 模型相结合,避免了深度学习网络模型无法确保输出实体标签的一致性,其 F 值同 BiLSTM 模型相比提升了 3.94%,使得在民航突发事件实体识别上取得了较好的效果。

5 结 语

本文针对民航突发事件实体自动获取的问题,提出了一种基于 BiLSTM—CRF 的民航突发事件实体识别方法。该方法在完成实体识别的同时,可以有效实现非结构化民航突发事件文本信息的结构化。实验表明,该模型避免了大量使用人工定义特征模板,同时,F 值较基于统计机器学习方法有了进一步的提升。但是,该方法没有考虑更多实体的局部特征,未来将重点关注对民航突发事件实体识别有重要影响的字符,引入注意力机制等方法进一步深入研究。

参 考 文 献

- [1] Pujara J, Miao H, Getoor L, et al. Knowledge graph identification [C]//International Semantic Web Conference. Springer, Berlin, Heidelberg, 2013: 542–557.
- [2] Kejrival M. Domain-specific knowledge graph construction [M]. Springer, 2019.
- [3] 侯梦薇,卫荣,陆亮,等.知识图谱研究综述及其在医疗领域的应用[J].计算机研究与发展,2018,55(12):2587–2599.
- [4] 袁凯琦,邓扬,陈道源,等.医学知识图谱构建技术与研究进展[J].计算机应用研究,2018,35(7):1929–1936.
- [5] 袁琦,刘渊,谢振平,等.宠物知识图谱的半自动化构建方法[J/OL].计算机应用研究:1–7[2019–04–25].https://doi.org/10.19734/j.issn.1001–3695.2018.05.0490.
- [6] Christopher J. Introducing the knowledge graph: things, not strings[EB/OL].(2012–05–24).https://mondaybymoon.com/introducingthe-knowledge-graph-things-not-strings/.
- [7] Auer S, Bizer C, Kobilarov G, et al. Dbpedia: A nucleus for a web of open data[M]//The semantic web. Springer, Berlin, Heidelberg, 2007: 722–735.
- [8] 张晓艳,王挺,陈火旺.命名实体识别研究[J].计算机学报,2005,32(4):44–48.
- [9] 杨锦锋,于秋滨,关毅,等.电子病历命名实体识别和实体关系识别研究综述[J].自动化学报,2014,40(8):1537–1562.
- [10] 刘凯,周雪忠,于剑,等.基于条件随机场的中医临床病历命名实体抽取[J].计算机工程,2014,40(9):312–316.
- [11] 邱泉清,苗夺谦,张志飞.中文微博命名实体识别[J].计算机科学,2013,40(6):196–198.
- [12] 朱颖东,杨立志,丁温雪,等.基于主题标签和 CRF 的中文微博命名实体识别[J].华中师范大学学报(自然科学版),2018,52(3):316–321.
- [13] 李想,魏小红,贾璐,等.基于条件随机场的农作物病虫害及农药命名实体识别[J].农业机械学报,2017,48(S1):178–185.

- [14] 冯艳红,于红,孙庚,等. 基于词向量和条件随机场的领域术语识别方法[J]. 计算机应用, 2016, 36(11): 3146-3151.
- [15] 孙娟娟,于红,冯艳红,等. 基于深度学习的渔业领域命名实体识别[J]. 大连海洋大学学报, 2018, 33(2): 265-269.
- [16] 丁晟春,王莉,刘梦露. 基于规则的动物卫生事件舆情信息抽取研究[J]. 计算机应用与软件, 2018, 35(9): 56-62.
- [17] 冯蕴天,张宏军,郝文宁. 面向军事文本的命名实体识别[J]. 计算机科学, 2015, 42(7): 15-18, 47.
- [18] 余晨,毛喆,高嵩. 基于规则的海事自由文本信息识别方法研究[J]. 交通信息与安全, 2017, 35(2): 40-47.
- [19] Liu H, Chen C, Zhang L, et al. The research of label-mapping-based entity attribute extraction[C]//2010 IEEE International Conference on Progress in Informatics and Computing. IEEE, 2010: 635-639.
- [20] 叶正,林鸿飞,苏绥,等. 基于支持向量机的人物属性抽取[J]. 计算机研究与发展, 2007, 44(S2): 271-275.
- [21] Huang R, Riloff E. Classifying message board posts with an extracted lexicon of patient attributes[C]//Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing. 2013: 1557-1562.
- [22] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [23] Hammerton J. Named entity recognition with long short-term memory[C]// Conference on Natural Language Learning at Hlt-naacl. 2003.
- [24] 冯艳红,于红,孙庚,等. 基于 BLSTM 的命名实体识别方法[J]. 计算机科学, 2018, 45(2): 261-268.
- [25] Graves A, Schmidhuber J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures[J]. Neural Netw, 2005, 18(5): 602-610.
- [26] Peng N, Dredze M. Named entity recognition for chinese social media with jointly trained embeddings[C] //Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing. 2015: 548-554.
- [27] 世界事故调查跟踪[EB/OL]. Aviation Safety Information System of CAAC. [2018-09]. <http://safety.caac.gov.cn/index/initpage.act>.
- [28] 何炎祥,罗楚威,胡彬尧. 基于 CRF 和规则相结合的地理命名实体识别方法[J]. 计算机应用与软件, 2015, 32(1): 179-185, 202.
- [13] 张勇,李飞腾,王昱. 基于 KDDA 和 SFLA-LSSVR 算法的 WLAN 室内定位算法[J]. 计算机研究与发展, 2017, 54(5): 979-985.

~~~~~

(上接第 159 页)

~~~~~

(上接第 130 页)

- [3] 吴心筱,伍堃. 利用深度神经网络的无监督视频表示[J]. 北京交通大学学报, 2017, 41(6): 8-12.
- [4] 朱煜,赵江坤,王逸宁,等. 基于深度学习的人体行为识别算法综述[J]. 自动化学报, 2016, 42(6): 848-857.
- [5] 叶茂权. 基于视频的人体行为识别的理论与方法研究[D]. 成都:电子科技大学, 2018.
- [6] 余兴. 基于深度学习的视频行为识别技术研究[D]. 成都:电子科技大学, 2018.
- [7] 高阳. 基于双流卷积神经网络的监控视频中打斗行为识别研究[D]. 西安:西安理工大学, 2018.
- [8] Tran D, Bourdev L, Fergus R, et al. Learning spatiotemporal features with 3d convolutional networks[C]//Proceedings of the IEEE International Conference on Computer Vision. 2015: 4489-4497.
- [9] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE International Conference on Computer Vision and Pattern Recognition. Las Vegas:IEEE, 2016:770-778.
- [10] Iandola F N, Han S, Moskewicz M W, et al. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size[EB]. arXiv preprint arXiv:1602.07360, 2016.
- [11] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions[C]//Computer Vision and Pattern Recognition. 2014: 1-9.
- [12] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision[C]//Proceedings of the IEEE International Conference on Computer Vision and Pattern Recognition. Las Vegas:IEEE, 2016:2818-2826.
- [13] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]//International Conference on International Conference on Machine Learning. 2015:448-456.
- [14] Donahue J, Hendricks L A, Guadarrama S, et al. Long-term recurrent convolutional networks for visual recognition and description[C]//Computer Vision and Pattern Recognition. IEEE, 2015:677.
- [15] 周文. 人体行为时空特征提取与识别算法设计与实现[D]. 北京:北京交通大学, 2018.
- [16] Wang L, Xiong Y, Wang Z, et al. Temporal segment networks: Towards good practices for deep action recognition[J]. Acm Transactions on Information Systems, 2016, 22(1): 20-36.