

## 引文格式：

方美丽, 郑莹莹, 陶坤旺, 等. 基于 MacBERT 和对抗训练的城市内涝信息识别方法 [J]. 集成技术, 2023, 12(1): 56-67.  
Fang ML, Zheng YY, Tao KW, et al. Urban waterlogging information recognition method based on MacBERT and adversarial training [J]. Journal of Integration Technology, 2023, 12(1): 56-67.

# 基于 MacBERT 和对抗训练的城市内涝信息识别方法

方美丽<sup>1,3</sup> 郑莹莹<sup>2\*</sup> 陶坤旺<sup>3</sup> 赵习枝<sup>3</sup> 仇阿根<sup>3</sup> 陆文<sup>2</sup>

<sup>1</sup>(江苏海洋大学海洋技术与测绘学院 连云港 222005)

<sup>2</sup>(中国科学院软件所 北京 100190)

<sup>3</sup>(中国测绘科学研究院 北京 100830)

**摘要** BERT 与神经网络模型相结合等方法, 已逐渐应用于获取灾害信息, 但此类方法存在参数量繁多、数据集和微调数据集不一致、局部不稳定等问题。针对上述问题, 该文提出一种基于 MacBERT 和对抗训练的信息识别模型, 该模型利用 MacBERT 预训练模型获得初始向量表示, 再加入些许扰动生成对抗样本, 然后依次输入双向长短期记忆网络和条件随机场。该模型不仅减少了预训练次数和微调阶段差异, 还提高了模型的鲁棒性。实验结果表明, 在微博数据集和 1998 年人民日报数据集上, 基于 MacBERT 和对抗训练的信息识别模型的精确率和  $F_1$  值均有所提升, 性能较其他模型更优, 将该模型用于城市内涝信息识别具有一定的可行性。

**关键词** 城市内涝; 信息识别; MacBERT; 对抗训练

中图分类号 P 208 文献标志码 A doi: 10.12146/j.issn.2095-3135.20220715002

## Urban Waterlogging Information Recognition Method Based on MacBERT and Adversarial Training

FANG Meili<sup>1,3</sup> ZHENG Yingying<sup>2\*</sup> TAO Kunwang<sup>3</sup> ZHAO Xizhi<sup>3</sup> QIU Agen<sup>3</sup> LU Wen<sup>2</sup>

<sup>1</sup>(School of Marine Technology and Geomatics, Jiangsu Ocean University, Lianyungang 222005, China)

<sup>2</sup>(Institute of Software Chinese Academy of Sciences, Beijing 100190, China)

<sup>3</sup>(Chinese Academy of Surveying and Mapping, Beijing 100830, China)

\*Corresponding Author: lvy5427@163.com

**Abstract** Methods such as BERT and the combination of neural network model have been gradually

收稿日期: 2022-07-15 修回日期: 2022-10-25

基金项目: 国家重点研发计划项目(物理—数字空间交融的城市管理和服务技术: 2019YFB2102503); 中国测绘科学研究院基本科研业务费项目(地理空间大数据治理关键技术研究: AR2111)

作者简介: 方美丽, 硕士研究生, 研究方向为数字城市空间信息采集与处理; 郑莹莹(通讯作者), 中级工程师, 研究方向为自然语言处理, E-mail: lvy5427@163.com; 陶坤旺, 副研究员, 研究方向为地理信息分析; 赵习枝, 助理研究员, 研究方向为夜间灯光遥感; 仇阿根, 研究员, 研究方向为政府地理信息服务与地理空间大数据技术; 陆文, 助理工程师, 研究方向为计算机软件与理论。

applied to the acquisition of disaster information. However, such methods have many problems, such as large number of parameters, inconsistent data sets and fine-tuning data sets, and local instability. In this paper, an information recognition model based on MacBERT and adversarial training is proposed. The model obtains the initial vector representation through MacBERT pre-training model, and then adds some perturbations to generate adversarial samples. Then input to the bi-directional long short-term memory and conditional random field in turn, which not only reduces the pre-training times and fine-tuning stage differences, but also improves the robustness of the model. The experimental results show that the information recognition model based on MacBERT and adversarial training are improved the accuracy rate and  $F_1$  value on the microblog dataset and the 1998 People's Daily dataset, and the execution is excellent than other models, which indicates that the model has certain feasibility for urban waterlogging information recognition.

**Keywords** urban waterlogging; information recognition; MacBERT; adversarial training

**Funding** This work is supported by National Key Research and Development Program of China (Urban Management and Service Technology for Physical and Digital Spatial Integration: 2019YFB2102503), Basic Research Funds of the Chinese Academy of Surveying and Mapping (Key Technology Research of Geospatial Big Data Governance: AR2111)

## 1 引言

目前, 全球气候变暖, 极端天气突发, 由于强降水或连续性降水造成的城市内涝灾害, 对人们的出行、交通造成了影响, 严重时甚至会造成财产损失、危害人身安全。据有关资料统计, 在我国 500 多个城市中, 约有 62% 的地区经历过内涝, 其中, 出现内涝灾情 3 次以上的城市为 137 个, 积水连续时间 > 12 h 的城市为 57 个<sup>[1]</sup>。由此可见, 城市内涝问题已经成为当前我国城市安全发展所面对的重大挑战。当灾害发生时, 能够准确有效地从各大社交媒体中获取灾害的发生时间、空间位置、造成的损失及灾害影响、致灾原因等信息, 不仅有助于提高城市管理工作者灾害应急响应能力, 还能为灾害监测<sup>[2]</sup>和城市舆情分析<sup>[3]</sup>提供数据支持。

城市内涝信息识别过程即命名实体识别的过程, 主要分为 3 种类型: 基于规则与词典的方法、基于传统机器学习的方法和基于深度学习的

方法<sup>[4]</sup>。其中, 基于规则与词典的方法, 主要是利用由语言学家基于数据集特征人工构建的特殊规范模板或特殊字典, 完成特征实体识别<sup>[5]</sup>。但这种方法不仅需要大量的人力和时间, 而且当实体类型不同时, 须重新制定相应的规范, 可移植性较差; 基于传统机器学习的方法, 意在将命名实体识别归为序列标注问题<sup>[6]</sup>, 但该方法依附于特征模板的选取, 泛化能力较差; 目前, 基于深度学习的方法逐渐兴起, 深度学习是由多层神经网络组成的机器学习算法<sup>[7]</sup>, 可有效提取特征并进行学习。

本文利用深度学习的方法对城市内涝信息进行识别, 将原始数据集送入 MacBERT 预训练模型获得初始向量表示, 再加入一些扰动生成对抗样本, 然后依次输入双向长短期记忆网络 (Bi-directional Long Short-Term Memory, BiLSTM)<sup>[8]</sup>和条件随机场 (Conditional Random Field, CRF)<sup>[9]</sup>进行训练学习, 最后在微博数据集和 1998 年人民日报数据集上测试该模型的性能。

## 2 信息识别研究现状

### 2.1 基于规则与词典的方法

基于规则与词典的方法是手工编写、人为设定的规则。Wang 等<sup>[10]</sup>结合规则与本体理论,从 Web 文档中提取灾害事件的时空和语义信息,探讨了事件在时空上的关系。霍娜等<sup>[11]</sup>基于规则匹配的方法,对 3 类灾难性追踪事件的相关文档进行信息提取,精确率均达 91% 以上,效果较好。将基于规则与词典的方法用于不同的领域时,由于不同领域内实体的规则不同,需要对规则进行改动,耗时耗力。当规则能较好地反映实体关系时,基于规则和词典的方法才较为方便。

### 2.2 基于传统机器学习的方法

目前,基于传统机器学习的方法主要有:支持向量机<sup>[12]</sup>、条件随机场(CRF)<sup>[13]</sup>、隐马尔可夫模型<sup>[14]</sup>等。基于传统机器学习的方法利用大规模语料进行学习,进而标注出模型,以发现特征。基于传统机器学习的方法进行语料的标注时不需要很多专业知识,且应用于其他领域时,可直接使用,无须再做很多烦琐的工作。Imran 等<sup>[15]</sup>通过朴素贝叶斯设计了一个信息消息检测系统,用于获取灾害属性信息,完成信息识别。梁春阳<sup>[16]</sup>基于条件随机场模型,识别灾害文本中包含的时空和灾损信息,精确率为 90.3%,识别效果良好。但基于传统机器学习的方法对语料库依赖较大,且评估命名实体识别系统的大规模通用语料库较少,实用性较差。

### 2.3 基于深度学习的方法

无论是基于规则和词典的方法还是基于传统机器学习的方法,都需要人工处理大量的数据,且基于规则与词典的方法相对于传统机器学习方法需要很多的领域知识和资源,深度学习中的神经网络则可以自动学习和提取特征。目前,命名实体识别中的深度学习方法主要包括卷积神经网络、循环神经网络等<sup>[17]</sup>,还有经过一系列改良

的长短期记忆网络(Long Short-Term Memory, LSTM)<sup>[18]</sup>、BiLSTM<sup>[19]</sup>等模型。Bengio 等<sup>[20]</sup>提出将神经网络语言模型用于训练参数奠定了深度学习模型在自然语言处理中的基础。Kumar 等<sup>[21]</sup>基于卷积神经网络模型,提取推特网上灾难事件及相关人员的地理位置,识别效果良好。Chanda<sup>[22]</sup>利用 BERT 模型,对 Twitter 数据使用不同类型的词嵌入以预测灾难, $F_1$  值为 83.16%,表明该模型的识别效果良好。Liu 等<sup>[23]</sup>将信息提取过程视为序列标注任务,结合 BERT 模型,从定制语料中提取台风灾害事件元素,有助于分析台风灾害的演化过程。刘淑涵等<sup>[24]</sup>利用卷积神经网络模型对北京特大暴雨灾害事件进行信息提取,精确度、召回率和  $F_1$  值均高达 80%,表明该方法对灾害主题的识别准确性较高。王苾梓<sup>[25]</sup>基于 BiLSTM 与 CRF 模型提取上海市内涝灾害的地名信息,与条件随机场模型相比,该模型的  $F_1$  值提高了 12%,地名实体识别效果显著。吴建华等<sup>[26]</sup>针对微博中的突发事件,采用 BiLSTM、CRF 模型和分类分层标注进行时空信息识别,进一步提高了时空信息识别的精度。黄中元<sup>[27]</sup>基于 BERT 预训练模型,使用序列标注方法为每个字预测标签,对输出结果进行约束,并结合实际应用需要进一步对抽取出的时间和地点进行推理分析,得到时间和地点的标准化表达,应用效果较好。

虽然上述方法取得了良好的效果,但仍存在问题。首先,BERT 预训练模型包含数以亿计的参数,受模型规模大、延迟时间长等影响,模型预训练的工作量较大。同时,BERT 在训练时引用掩码语言模型,但目前大多数下游任务进行微调时,数据集中没有掩码数据,导致训练前数据集和微调数据集不一致,从而影响微调效果。其次,相关实验研究证明,神经网络模型常常表现为局部不稳定,即使输入很小的扰动,也可能在一定程度上误导模型,这种恶意扰动的输入即为对抗样本<sup>[28]</sup>。

本文利用 MacBERT 模型获取输入数据的向量表示, 不仅可以减少预训练, 而且可以不使用掩码标记, 将掩码标记位置的词替换为一个近义词, 然后让模型进行词语纠错。输入样本中由于没有掩码标记, 将大大减少微调阶段的差异。此外, 本文还通过对抗训练解决完善神经网络模型局部不稳定的问题。对抗训练是指在建立些许对抗样本的基础上, 将其添加到原数据集中, 以提高模型对对抗样本的鲁棒性, 强化模型对输入扰动的鲁棒性, 从而使其更有效运用于城市内涝信息识别任务。

### 3 城市内涝信息识别方法

#### 3.1 相关概念

##### 3.1.1 预训练模型

预训练模型是神经网络方法中不可或缺的内容, 预训练模型能够从没有标记完全的文本信息中获得先验语义知识, 从而促进下游任务的实施。2018 年, Devlin 等<sup>[29]</sup>提出了 BERT 预训练模型, 其编码器利用双向 Transformer, 实现了预训练的深度双向表示。BERT 模型采用掩码语言模型, 可以任意掩蔽输入词的 15%。其中, 直接被替换为[MASK]的占 80%, 任意词被更换占 10%, 剩下 10% 保留原始词。但目前大多下游任务进行微调时, 数据集中没有掩码数据, 导致预训练任务与下游微调任务不统一; 而 MacBERT 将[MASK]标记位置的词更换为另一个近义词, 可缓减预训练与微调阶段的误差, 从而获得词级信息。

BERT 和 MacBERT 的掩码方式对比如表 1 所示。

由表 1 可知, 输入文本“今天的风实在太大了, 还赶上了暴雨”, BERT 是以字为粒度的掩码方法, 如对于原属于一个词的“今日的风”中的部分字“风”, 将其随机掩码并通过预测被掩码掉的字, 学习到字粒度的语义表示。而 MacBERT 则使用近义词代替[MASK], 没有近义词的用随机词替换, 学习词级别的语义表示, 该方法更适用于城市内涝信息识别任务。因此, 本文中输入文本的向量表示采用 MacBERT 模型获取。

##### 3.1.2 对抗训练

2015 年, Goodfellow 等<sup>[30]</sup>首次提出对抗训练的概念, 通过不断向模型输入扰动, 增强模型的鲁棒性。即向原始的输入样本  $X$  中加入些许扰动后得到对抗样本, 然后将对抗样本放入模型中进行训练。Yasunaga 等<sup>[31]</sup>在 POS 任务中使用对抗训练, 不但提升了整体标注的正确率, 还增强了模型的鲁棒性。李静等<sup>[32]</sup>基于局部对抗训练方法, 既减缓了边界样本混淆限制命名实体识别的问题, 又降低了传统对抗训练中由于计算增加引起的对抗样本冗余, 提高了命名实体识别效果。对抗训练的过程可以抽象为一个公式, 如公式(1)所示。

$$\min_{\theta} E_{(x,y) \sim D} \left[ \max_{\gamma_{adv} \in \Omega} L(\theta, x + \gamma_{adv}, y) \right] \quad (1)$$

其中,  $\gamma_{adv}$  为计算的扰动;  $\Omega$  为扰动空间;  $L$  为损失函数;  $\theta$  为模型内部相关参数;  $x$  为输入;  $y$  为输出;  $D$  为样本空间;  $E$  为经验风险。公式(1)可分

表 1 BERT 和 MacBERT 的掩码方式对比

Table 1 Comparison between BERT's and MacBERT's mask methods

说明	示例
原始句子	今天的风实在太大了, 还赶上了暴雨。
中文分词	今天 的 风 实 在 太 大 了 , 还 赶 上 了 暴 雨 。
BERT 掩码方式	今天 的 [MASK] 实 在 太 大 了 , 还 赶 上 了 [MASK] 雨 。
MacBERT 掩码方式	今天 的 风 确 实 极 大 了 , 还 遇 上 了 大 雨 。



为内外两部分：内部是对损失函数求最大值，外部是对经验风险求最小值，该公式表示在扰动范围内对输入样本加入扰动，使损失函数达到最大的扰动，可求得经验风险最小时对应的参数。

### 3.1.3 双向长短期记忆网络模型

循环神经网络对于文本序列的历史信息拥有记忆保存的能力，常用于执行序列的标注任务<sup>[33]</sup>。但由于序列长度的不断增加，出现了长距离依赖、梯度消失或爆炸等问题。因此，Hochreiter等<sup>[34]</sup>提出了长短期记忆网络模型，有效地解决了循环神经网络的长距离依赖与梯度消失的问题。然而，需要进行文本分析的词不仅与上文有关，还与下文密不可分。因此，Graves等<sup>[35]</sup>提出了BiLSTM模型，该模型基于前向长短期记忆网络和后向长短期记忆网络两个方向，能够同时对文本的上下文信息进行分析，有效地解决了长短期记忆网络分析文本信息的单向问题。双向长短期记忆网络模型的网络结构如图1所示。




图1 双向长短期记忆网络模型结构图

Fig. 1 BiLSTM model structure drawing

在双向长短期记忆网络模型中， $X_t$ 为 $t$ 时的输入； $\bar{P}_t$ 为 $t$ 时LSTM的正向输出； $\tilde{P}_t$ 为 $t$ 时LSTM的反向输出； $Y_t$ 为 $t$ 时双向长短期记忆网络的输出，其由两个方向的长短期记忆网络的状态决定。计算公式如下：

$$\bar{P}_t = LSTM(X_t, \bar{P}_{t-1}) \quad (2)$$

$$\tilde{P}_t = LSTM(X_t, \tilde{P}_{t-1}) \quad (3)$$

$$Y_t = w_t \bar{P}_t + v_t \tilde{P}_t + u_t \quad (4)$$

其中， $w_t$ 为正向输出的权重矩阵； $v_t$ 为反向输出的权重矩阵； $u_t$ 为 $t$ 时的偏置。

### 3.1.4 条件随机场模型

2001年，Lafferty等<sup>[36]</sup>提出的条件随机场模型综合了最大熵模型和隐马尔可夫模型的优势，可标记和分割有序数据。对于标签序列 $y = \{y_1, y_2, \dots, y_n\}$ ，其概率计算公式如公式(5)所示。

$$\rho(y|x) = \frac{\exp\left(\sum_i (S_{i,y_i} + H_{y_{i-1},y_i})\right)}{\sum_y \exp\left(\sum_i (S_{i,y_i} + H_{y_{i-1},y_i})\right)} \quad (5)$$

其中， $H$ 为转移矩阵； $H_{y_{i-1},y_i}$ 为标签 $y_{i-1}$ 至标签 $y_i$ 的转移分数； $S_{i,y_i}$ 为字符 $x_i$ 被推测为标签 $y_i$ 的分数； $y$ 为全部有可能的标签序列。

在解码过程中，可利用维特比算法计算得到最高分数的标签序列 $y^*$ ，计算公式如下：

$$y^* = \operatorname{argmax}_i \left( S_{i,y_i} + H_{y_{i-1},y_i} \right) \quad (6)$$

## 3.2 AT-MBC方法流程

本文提出基于对抗训练、MacBERT、BiLSTM、CRF相结合的城市内涝信息识别方法AT-MBC，结构图如图2所示。整个流程可分为6个部分：输入层、MacBERT层、对抗训练层、BiLSTM层、CRF层和输出层。该方法工作流程为：(1)将数据集组成文本 $X(X_1, X_2, \dots, X_n)$ ，并输入MacBERT层，其中， $X_i$ 表示输入文本中的第 $i$ 个词；(2)利用MacBERT得到输入文本的初始向量表示 $E = (E_1, E_2, \dots, E_n)$ ，在 $E = (E_1, E_2, \dots, E_n)$ 上增加扰动 $\gamma = (\gamma_1, \gamma_2, \dots, \gamma_n)$ 以产生对抗样本，然后将 $E = (E_1, E_2, \dots, E_n)$ 与 $\gamma = (\gamma_1, \gamma_2, \dots, \gamma_n)$ 一并输入BiLSTM层；(3)计算双向LSTM在各个时间步的输入特征，利用BiLSTM的正反向LSTM抽取出上下文的特征信息，并通过位置拼接得到特征矩阵 $C = (C_1, C_2, \dots, C_n)$ ，用于抽取句中的语义信息；(4)在CRF层中，思考标注中的转移特征，获取相邻标签中的依附关系，输出对应的标签

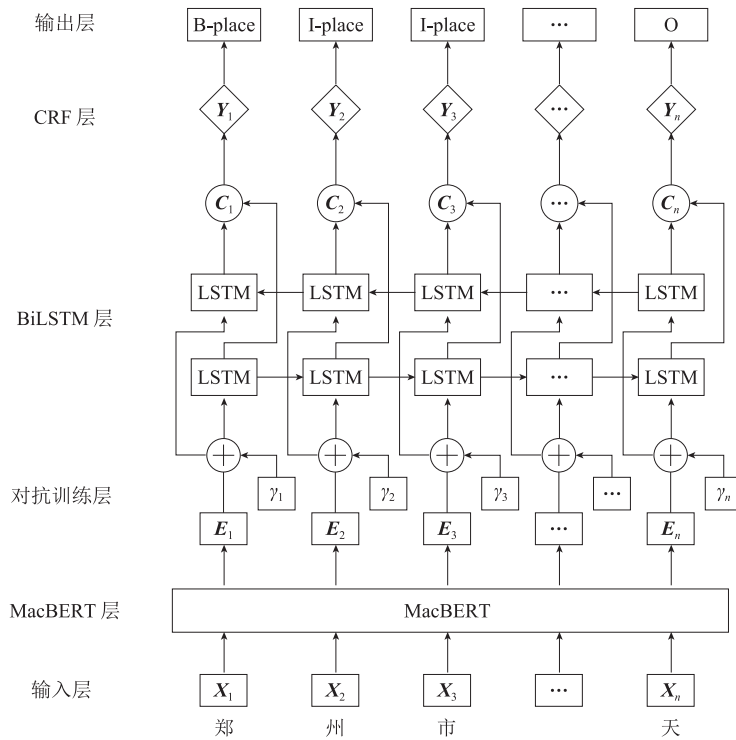


图 2 AT-MBC 模型结构图

Fig. 2 The AT-MBC model diagram

$Y(Y_1, Y_2, \dots, Y_n)$ , 以得到最后的标注结果。

条件随机场常被标签解码层用以计算最有可能的命名实体类别, 它通过学习一些规范以确保有效的最终预测结果, 减少非法序列的出现。条件随机场的规范如下: (1) 实体以“B-”开头, 句子首字符以“B-”或“O”开始, 实体或句首均不能以“I-”开始。(2) 对于连续标签, 如以“B-place”为首, 后面的标签只能是“I-place”标签或“O”标签。

如在输入层中输入郑州市遭遇强降雨天气, 在输出层就会输出郑/B-place 州/I-place 市/I-place 遭/O 遇/O 强/B-attribute 降/I-attribute 雨/I-attribute 天/O 气/O。

## 4 实验与结果

### 4.1 实验环境与数据

本文的实验硬件环境如表 2 所示。

表 2 实验硬件环境

Table 2 Experimental hardware environment

参数	参数值
CPU	E5-2680
GPU	A4000
计算机内存	16 GB
操作系统	Linux
深度学习框架	PyTorch
编程语言	Python

首先, 本文基于网络爬虫技术, 根据“内涝”“积水”“冲走”“水淹”等关键词及时间范围, 获取相关的新浪微博内容, 共收集整理了关于河南省郑州市 7 月 20 日内涝灾害事件的 110 473 条文本数据。

然后, 对原数据进行清洗去重、中文分词、去除停用词等工作。其中, 清洗去重是将原数据中无用的信息去除, 便于后期分析; 中文分词是将某个中文句子变换成词序列; 去除停用词是去除自然语言中频繁出现, 但不一定代表句子实质

语义的词<sup>[37]</sup>，如“的”“地”“得”等，该工作可以提升模型的运算效率并降低错误率。

最后，结合对抗训练、MacBERT、BiLSTM和CRF模型，提取郑州市内涝事件的时间信息、地理位置信息和属性信息。其中，属性信息包含灾害产生的原因，造成房屋破坏、道路损毁、车辆损坏、人员伤亡、经济损失等影响。数据集采用BIO标注机制：B-time表示时间在此段的开头，I-time表示时间在此段的中间位置；B-place表示地名在此段的开头，I-place表示地名在此段的中间位置；B-attribute表示属性在此段的开头，I-attribute表示属性在此段的中间位置；O表示不是实体。时间信息、地理位置信息和属性信息部分数据如表3所示。

将数据按照7:3划分训练集和测试集，即在语料库中随机选取14331条语句作为训练集，余下的6142条为测试语料库，数据集整体情况如表4所示。

表4 语料数据统计

Table 4 Corpus statistics

语料	训练集	测试集
字数	615 743	267 991
句子数	14 331	6 142
时间数	2 773	1 231
地理位置数	6 720	3 023
属性数	3 377	1 440

表3 部分数据

Table 3 Part of data

数据种类	数据内容
原始数据	早/O 关/O 注/O, /O 河/B-place 南/I-place 郑/I-place 州/I-place 遭/O 遇/O 强/B-attribute 降/I-attribute 雨/I-attribute 天/O 气/O, /O 多/O 地/O 内/O 涝/O, /O 河/O 流/O 水/O 位/O 持/O 续/O 上/O 涨/O, /O 险/O 情/O。/O 2/B-time 1/I-time 日/I-time 晚/I-time, /O 2/B-attribute 5/I-attribute 人/I-attribute 遇/I-attribute 难/I-attribute、/O 7/B-attribute 人/I-attribute 失/I-attribute 联/I-attribute、/O 1/B-attribute 2/I-attribute 0/I-attribute 余/I-attribute 万/I-attribute 人/I-attribute 受/I-attribute 灾/I-attribute, /O 各/O 项/O 救/O 灾/O 工/O 作/O 正/O 展/O 开/O。/O
时间数据	21日晚
地理位置数据	河南郑州
属性数据	强降雨; 25人遇难; 7人失联; 120余万人受灾

## 4.2 实验参数与评价标准

本实验使用Google发布的MacBERT预训练模型，模型参数如表5所示。

表5 MacBERT模型参数

Table 5 MacBERT model parameters

参数	参数值	说明
Hidden size	768	隐单元维度
Embedding size	768	词嵌入维度
Max position embeddings	512	最大位置嵌入
Num attention heads	12	多头数目
Num hidden layers	12	隐藏层数
Maximal length sequence	128	最大序列长度
Epoch	20	迭代次数
Dropout	0.5	正则化
Batch size	32	训练样本数量
Learning rate	10 <sup>-5</sup>	学习率
Optimizer	AdamW	优化器

本文利用精确率(Precision,  $P$ )、召回率(Recall,  $R$ )和综合值 $F_1$ 对模型效果进行评估，计算公式如下：

$$P = \frac{TP}{TP + FP} \quad (7)$$

$$R = \frac{TP}{TP + FN} \quad (8)$$

$$F_1 = \frac{2PR}{P + R} \quad (9)$$

其中， $TP$ 为识别到正确实体的个数； $FP$ 为

识别到非实体的个数;  $FN$  为未识别到正确实体的个数。

### 4.3 实验结果分析与讨论

本实验基于微博数据集对 AT-MBC 模型进行超参数敏感性和有效性分析: 分别将训练样本批大小和正则化 Dropout 作为变量, 探究模型对参数的敏感性; 选择另外 3 种信息识别模型与本实验改进模型 AT-MBC 对比分析, 探究模型的有效性。

#### 4.3.1 模型敏感性分析

批大小会影响模型的优化程度和速度, 合适的批大小能够提高训练的速度, 反之则会导致数据不收敛或运行内存不足。将模型批大小分别设置为 8、16、32、64、128 进行实验, 实验结果如图 3 所示。当批大小为 32 时到达峰值, 而召回率则达到低谷值。




图 3 批大小对模型评价指标的影响

Fig. 3 Effect of batch size on model evaluation index

正则化 Dropout 是指在深度学习网络的训练过程中, 按照一定的概率将一部分神经网络单元暂时从网络中丢弃, 可增强模型的泛化性。将 Dropout 值分别设置为 0.2、0.5 和 0.7 进行实验, 实验结果如图 4 所示。当 Dropout 值为 0.5 时, 模型效果最好。

#### 4.3.2 模型有效性分析

为证实本文设计的 AT-MBC 模型的有效性, 在同一训练集和测试集下, 选取 BiLSTM-CRF (BC)<sup>[38]</sup>、BERT-BiLSTM-CRF (BBC)<sup>[39]</sup>和

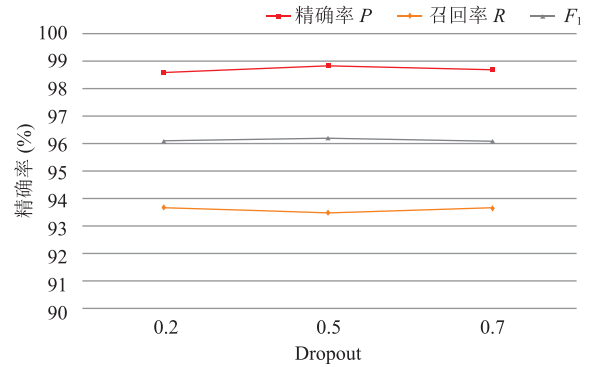


图 4 Dropout 对模型评价指标的影响

Fig. 4 Influence of Dropout on model evaluation index  
MacBERT-BiLSTM-CRF (MBC)<sup>[40]</sup>共 3 种模型进行实验对比, 表 6 为不同模型的内涝信息识别实验结果。

表 6 实验结果

Table 6 The experimental results

模型	精确率	召回率	$F_1$ 值 (%)
BC	98.69	91.55	92.00
BBC	98.75	92.82	92.19
MBC	98.77	93.34	92.11
AT-MBC	98.82	93.11	92.28

由表 6 可知, AT-MBC 模型的精确率为 98.82%, 召回率为 93.11%,  $F_1$  值为 92.28%, 信息识别状况表现良好。

BC 模型的精确率为 98.69%, 召回率为 91.55%,  $F_1$  值为 92.00%。与 BC 模型相比, BBC 模型的精确率提升了 0.06%, 召回率提升了 1.27%,  $F_1$  值提升了 0.19%。BC 模型的识别效果较差, 是因为该模型的预训练过程是静态的, 未考虑位置信息词的多层特性。当引入 BERT 预训练模型后, 模型的精确率、召回率与  $F_1$  值均有所提升, 说明 BERT 预训练模型训练得到的向量具有更多、更好的文本特征, 能较好地表征位置信息词的多义性。

BBC 模型的精确率为 98.75%, 召回率为 92.82%,  $F_1$  值为 92.19%。与 BBC 模型相比, MBC 模型的精确率提升了 0.02%, 召回



率提升了 0.52%。MBC 识别效果较好,是因为 MacBERT 模型改进了 BERT 模型的预训练任务,将原本需要掩码标记位置的词替换为别的近义词,然后让模型进行词语纠错,使得输入样本中没有掩码标记。这样不仅减少了预训练,还大大降低了微调阶段的差异。

MBC 模型的精确率为 98.77%,召回率为 93.34%, $F_1$  值为 92.11%。与 MBC 模型相比,AT-MBC 模型的精确率提升了 0.05%, $F_1$  值提升了 0.17%。AT-MBC 模型的识别效果较好,是因为对抗训练是直接在模型的向量表示上添加一些扰动生成对抗样本,而对抗样本会在一定程度上模拟数据集中的自然误差,使模型更能容忍模型参数波动带来的变化,从而增强了模型对对抗样本的鲁棒性。

综上所述,本文提出的 AT-MBC 模型信息识别方法的性能更优。

为更加直观地研究参数对于模型的敏感性和有效性,本文通过设置不同的迭代次数,以分析模型的精确率和  $F_1$  值涨幅情况,如图 5、图 6 所示。

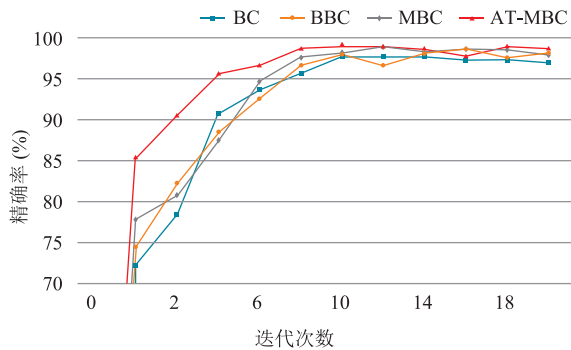


图 5 迭代次数对模型精确率的影响

Fig. 5 Effect of iteration number on model accuracy

由图 5、图 6 可知,随着训练迭代次数增加,各个模型的指标曲线呈先增长后逐渐拟合并趋于稳定的趋势。其中,AT-MBC 模型精确率和  $F_1$  值的增速较快,在第 10 次迭代时达到最大值,且相较于其他模型,该模型的效果最好。

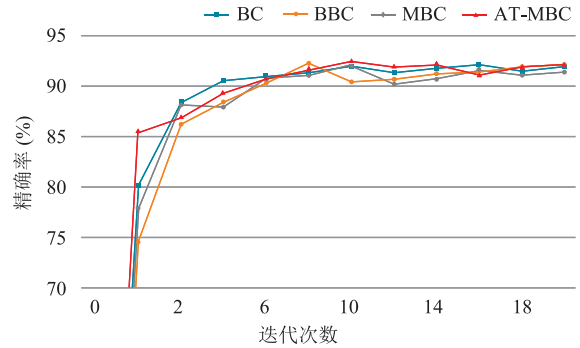


图 6 迭代次数对  $F_1$  指标的影响

Fig. 6 The influence of iteration times on  $F_1$  index

为再次证明本文方法的先进性,本文选用公开数据集(由北京大学标注的 1998 年《人民日报》语料)进行实验,并与部分现有方法进行实验对比,对比结果如表 7 所示。

表 7 实验对比

Table 7 The experimental contrast

方法	精确率	召回率	$F_1$ 值
杨贺羽等 <sup>[41]</sup> 方法	90.36	92.26	91.30
金彦亮等 <sup>[42]</sup> 方法	92.26	90.58	91.41
蔡庆 <sup>[43]</sup> 方法	94.54	94.10	94.32
本文方法	95.72	95.57	95.45

如表 7 所示,杨贺羽等<sup>[41]</sup>通过双向长短期记忆网络和 FOFE 编码,对向量化表示的文本进行特征提取和编码表示,精确率高达 90.36%。金彦亮等<sup>[42]</sup>提出基于分层标注的实体抽取方法, $F_1$  值达到了 91.41%,有效地改善了中文嵌套命名实体识别的效果。蔡庆<sup>[43]</sup>利用 BERT 预训练结合深度神经网络和 CRF 模型,提升了实体识别的效果。而本文提出的 AT-MBC 模型的精确率、召回率和  $F_1$  值均高于上述模型。因此,本文提出的 AT-MBC 模型具有更强的信息提取能力,可有效地应用于信息识别任务。

## 5 结束语

在本文提出的 AT-MBC 算法模型中,

MacBERT 层减少了预训练次数和微调阶段差异, BiLSTM 层负责提取文本上下文语义特征, CRF 层负责生成最优标签序列, 并通过对抗训练提高了该模型的鲁棒性, 可有效实现城市内涝信息识别。由实验结果可知, 本文提出的 AT-MBC 算法的各种指标均较好, 可为城市管理工作的信息识别分析研究提供参考。本文提出的识别方法还存在一定弊端, 尤其是面对复杂地理位置信息和复杂属性信息时, 需进一步完善信息识别方法。下个阶段可收集其他各大社交媒体网络网站上的复杂地理位置数据集与复杂属性数据集, 对实验结果进行分析和深入研究, 同时不断优化参数设置, 以取得更好的识别效果。

### 参 考 文 献

- [1] 孔锋. 我国城市暴雨内涝灾害风险综合治理初探 [J]. 中国减灾, 2021, (17): 23-27.  
Kong F. Preliminary study on comprehensive management of urban rainstorm and waterlogging disaster risk in China [J]. Disaster Reduction in China, 2021, (17): 23-27.
- [2] 梁好, 段丽瑶, 霍凯, 等. 天津城市自动化内涝监测预警系统设计与实现 [J]. 中国防汛抗旱, 2020, 30(6): 27-31.  
Liang H, Duan LY, Huo K, et al. Design and application of urban waterlogging automatic monitoring and early warning system in Tianjin [J]. China Flood & Drought Management, 2020, 30(6): 27-31.
- [3] 吴克昌, 叶阳澍. 顺势而为: 公共事件网络舆情干预策略——基于“寿光洪水”新浪微博文本 [J]. 华南理工大学学报(社会科学版), 2019, 21(2): 33-45.  
Wu KC, Ye YP. Follow the trend: the intervention strategy for internet sentiment of public events——based on Sina Weibo content of “Shouguang Hongshui” [J]. Journal of South China University of Technology (Social Science Edition), 2019, 21(2): 33-45.
- [4] 朱鹏, 石丽红, 焦明连, 等. 混合神经网络的中文地名识别方法 [J]. 测绘科学, 2021, 46(11): 159-165.  
Zhu P, Shi LH, Jiao ML, et al. Chinese place name recognition based on hybrid neural network [J]. Science of Surveying and Mapping, 2021, 46(11): 159-165.
- [5] 赵辉, 庞海婷, 冯珊珊, 等. 中文命名实体识别技术综述 [J]. 长春工业大学学报, 2021, 42(5): 444-450.  
Zhao H, Pang HT, Feng SS, et al. Summary of Chinese named entity recognition technology [J]. Journal of Changchun University of Technology, 2021, 42(5): 444-450.
- [6] 陈曙东, 欧阳小叶. 命名实体识别技术综述 [J]. 无线电通信技术, 2020, 46(3): 251-260.  
Chen SD, Ouyang XY. Overview of named entity recognition technology [J]. Radio Communications Technology, 2020, 46(3): 251-260.
- [7] Nasir JA, Khan OS, Varlamis I. Fake news detection: a hybrid CNN-RNN based deep learning approach [J]. International Journal of Information Management Data Insights, 2021, 1(1): 100007.
- [8] Peng T, Zhang C, Zhou JZ, et al. An integrated framework of Bi-directional long-short term memory (BiLSTM) based on sine cosine algorithm for hourly solar radiation forecasting [J]. Energy, 2021, 221: 119887.
- [9] Chen DP, Xu D, Li HS, et al. Group consistent similarity learning via deep CRF for person re-identification [C] // Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 8649-8658.
- [10] Wang W, Stewart K. Spatiotemporal and semantic information extraction from Web news reports about natural hazards [J]. Computers, Environment and Urban Systems, 2015, 50: 30-40.
- [11] 霍娜, 吕国英. 基于规则匹配的灾难性追踪事件信息抽取的研究 [J]. 电脑开发与应用, 2012, 25(6): 7-9+13.  
Huo N, Lv GY. Research on sudden event information extraction of tracking reports based on rules [J]. Computer Development & Applications, 2012, 25(6): 7-9+13.
- [12] Huang SJ, Cai NG, Pacheco PP, et al. Applications of support vector machine (SVM) learning in cancer

- genomics [J]. *Cancer Genomics & Proteomics*, 2018, 15(1): 41-51.
- [13] Tang SX, Chen DP, Bai L, et al. Mutual CRF-GNN for few-shot learning [C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2021: 2329-2339.
- [14] Deng Q, Söffker D. A review of HMM-based approaches of driving behaviors recognition and prediction [J]. *IEEE Transactions on Intelligent Vehicles*, 2021, 7(1): 21-31.
- [15] Imran M, Elbassuoni S, Castillo C, et al. Extracting information nuggets from disaster-related messages in social media [C] // *Proceedings of the International Conference on Information Systems for Crisis Response and Management*, 2013: 791-801.
- [16] 梁春阳. 基于社交媒体的台风灾情信息抽取方法研究 [D]. 福州: 福建师范大学, 2019.  
Liang CY. A method of extration typhoon disaster information using social media data [D]. Fuzhou: Fujian Normal University, 2019.
- [17] 何玉洁, 杜方, 史英杰, 等. 基于深度学习的命名实体识别研究综述 [J]. *计算机工程与应用*, 2021, 57(11): 21-36.  
He YJ, Du F, Shi YJ, et al. Survey of named entity recognition based on deep learning [J]. *Computer Engineering and Applications*, 2021, 57(11): 21-36.
- [18] Merity S, Keskar NS, Socher R. Regularizing and optimizing LSTM language models [EB/OL]. (2017-08-07)[2022-07-15]. <https://arXiv.org/abs/1708.02182>.
- [19] 周雪晴, 张占松, 朱林奇, 等. 基于双向长短期记忆网络的流体高精度识别新方法 [J]. *中国石油大学学报(自然科学版)*, 2021, 45(1): 69-76.  
Zhou XQ, Zhang ZS, Zhu LQ, et al. A new method for high-precision fluid identification in bidirectional long short-term memory network [J]. *Journal of China University of Petroleum (Edition of Natural Science)*, 2021, 45(1): 69-76.
- [20] Bengio Y, Ducharme R, Vincent P, et al. A neural probabilistic language model [J]. *Journal of Machine Learning Research*, 2003(3): 137-186.
- [21] Kumar A, Singh JP. Location reference identification from tweets during emergencies: a deep learning approach [J]. *International Journal of Disaster Risk Reduction*, 2019, 33: 365-375.
- [22] Chanda AK. Efficacy of BERT embeddings on predicting disaster from Twitter data [EB/OL]. (2021-08-08)[2022-07-15]. <https://arXiv.org/abs/2108.10698>.
- [23] Liu HL, Luo NX, Zhao QS. Research on the construction of typhoon disaster chain based on Chinese Web corpus [J]. *Journal of Marine Science and Engineering*, 2022, 10(1): 44.
- [24] 刘淑涵, 王艳东, 付小康. 利用卷积神经网络提取微博中的暴雨灾害信息 [J]. *地球信息科学学报*, 2019, 21(7): 1009-1017.  
Liu SH, Wang YD, Fu XK. Extracting rainstorm disaster information from microblogs using convolutional neural network [J]. *Journal of Geo-information Science*, 2019, 21(7): 1009-1017.
- [25] 王蕊梓. 社交媒体中城市内涝信息提取与分析 [D]. 上海: 华东师范大学, 2020.  
Wang JZ. Urban waterlogging information extraction and analysis using social media [D]. Shanghai: East China Normal University, 2020.
- [26] 吴建华, 胡烈云, 赵宇, 等. 基于 BiLSTM-CRF 与分类分层标注的微博中突发事件时空信息精细识别方法 [J]. *地理与地理信息科学*, 2021, 37(3): 1-8.  
Wu JH, Hu LY, Zhao Y, et al. Method of finely identifying spatio-temporal information of emergencies from weibo based on BiLSTM-CRF and classified-hierarchical annotation [J]. *Geography and Geo-Information Science*, 2021, 37(3): 1-8.
- [27] 黄中元. 基于短文本的灾害领域事件抽取方法研究及应用 [D]. 哈尔滨: 哈尔滨工业大学, 2021.  
Huang ZY. Research and application of event extraction method in disaster field based on short text [D]. Harbin: Harbin Institute of Technology, 2021.
- [28] Miyato T, Dai AM, Goodfellow I. Adversarial training methods for semi-supervised text classification [EB/OL]. (2016-05-25)[2022-07-15]. <https://arXiv.org/abs/1605.07725>.
- [29] Devlin J, Chang MW, 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: Human Language Technologies, 2019: 4171-4186.
- [30] Goodfellow IJ, Shlens J, Szegedy C. Explaining and harnessing adversarial examples [EB/OL]. (2014-11-20)[2022-07-15]. <https://arXiv.org/abs/1412.6572>.
- [31] Yasunaga M, Kasai J, Radev D. Robust multilingual part-of-speech tagging via adversarial training [C] // Proceeding of the 2018 Conference on the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2018: 976-986.
- [32] 李静, 程芃森, 许丽丹, 等. 基于局部对抗训练的命名实体识别方法研究 [J]. 四川大学学报(自然科学版), 2021, 58(2): 113-120.  
Li J, Cheng PS, Xu LD, et al. Name entity recognition based on local adversarial training [J]. Journal of Sichuan University (Natural Science Edition), 2021, 58(2): 113-120.
- [33] 赵宏, 王乐, 王伟杰. 基于 BiLSTM-CNN 串行混合模型的文本情感分析 [J]. 计算机应用, 2020, 40(1): 16-22.  
Zhao H, Wang L, Wang WJ. Text sentiment analysis based on serial hybrid model of bidirectional long short-term memory and convolutional neural network [J]. Journal of Computer Applications, 2020, 40(1): 16-22.
- [34] Hochreiter S, Schmidhuber J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.
- [35] Graves A, Schmidhuber J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures [J]. Neural Networks, 2005, 18(5): 602-610.
- [36] Lafferty J, McCallum A, Pereira FCN. Conditional random fields: probabilistic models for segmenting and labeling sequence data [J]. Proceedings of 18th International Conference on Machine Learning, 2001, 3(2): 282-289.
- [37] 喻鑫, 张亮, 冉钦朋, 等. 基于自然语言处理的防洪重大事件新闻舆情分析——以长江 5 号洪水为例 [J]. 水利信息化, 2022, (3): 50-56.
- Yu X, Zhang L, Ran QP, et al. Analysis on news and public opinions on major flood control events based on natural language processing——taking Yangtze River Flood No.5 as an example [J]. Water Resources Informatization, 2022, (3): 50-56.
- [38] Miao YL, Cheng WF, Ji YC, et al. Aspect-based sentiment analysis in Chinese based on mobile reviews for BiLSTM-CRF [J]. Journal of Intelligent & Fuzzy Systems, 2021, 40(5): 8697-8707.
- [39] Gao WC, Zheng XH, Zhao SS. Named entity recognition method of Chinese EMR based on BERT-BiLSTM-CRF [J]. Journal of Physics: Conference Series, 2021, 1848(1): 012083.
- [40] 焦凯楠, 李欣, 叶瀚, 等. 基于 MacBERT-BiLSTM-CRF 的反恐领域细粒度实体识别 [J]. 科学技术与工程, 2021, 21(29): 12638-12648.  
Jiao KN, Li X, Ye H, et al. Fine-grained entity based on MacBERT-BiLSTM-CRF in anti-terrorism field [J]. Science Technology and Engineering, 2021, 21(29): 12638-12648.
- [41] 杨贺羽, 杜洪波, 朱立军. 基于顺序遗忘编码和 Bi-LSTM 的命名实体识别算法 [J]. 计算机应用与软件, 2020, 37(2): 213-217.  
Yang HY, Du HB, Zhu LJ. Named entity recognition algorithm based on ordinaly forgetting encoding and Bi-LSTM [J]. Computer Applications and Software, 2020, 37(2): 213-217.
- [42] 金彦亮, 谢晋飞, 吴迪嘉. 基于分层标注的中文嵌套命名实体识别 [J]. 上海大学学报(自然科学版), 2022, 28(2): 270-280.  
Jin YL, Xie JF, Wu DJ. Chinese nested named entity recognition based on hierarchical tagging [J]. Journal of Shanghai University (Natural Science Edition), 2022, 28(2): 270-280.
- [43] 蔡庆. 多准则融合的中文命名实体识别方法 [J]. 东南大学学报(自然科学版), 2020, 50(5): 929-934.  
Cai Q. Chinese named entity recognition based on multi-criteria fusion [J]. Journal of Southeast University (Natural Science Edition), 2020, 50(5): 929-934.