

文章编号：2095-4980(2024)05-0503-13

实体识别技术研究进展综述

马艺洁¹, 赖海光², 刘子威¹, 杨楠¹, 张更新¹

(1.南京邮电大学 卫星通信研究所, 江苏 南京 210003; 2.南京控维通信科技有限公司, 江苏 南京 211135)

摘要：实体识别技术作为知识图谱构建的重要步骤，已广泛用于语义网络、机器翻译、问答系统等自然语言处理中，在推动自然语言处理技术落地实践的过程中起着非常关键的作用。本文根据实体识别技术的发展历程调研了现有的实体识别方法，主要为早期基于规则和词典的实体识别方法、基于机器学习的以及基于深度学习的命名实体识别方法；整理了每种实体识别方法的关键思路、优缺点和具有代表性的模型，特别对目前使用较多的基于双向长短句记忆网络(BiLSTM)模型和基于Transformer模型的实体识别方法进行了概述；介绍了目前主流的数据集以及评价标准。最后，面向未来机器类通信的语义需求，总结了实体识别技术面临的挑战，并对其未来在物联网业务数据方面的发展进行了展望。

关键词：实体识别；语义提取；深度学习；知识图谱

中图分类号：TN927.2

文献标志码：A

doi: 10.11805/TKYDA2023436

Overview of the research progress in entity recognition technology

MA Yijie¹, LAI Haiguang², LIU Ziwei¹, YANG Nan¹, ZHANG Gengxin¹

(1.Institute of Satellite Communication , Nanjing University of Posts and Telecommunications , Nanjing Jiangsu 210003 , China ;
2.Cowave Satellite Communication Technology Co., Ltd , Nanjing Jiangsu 211135 , China)

Abstract: Entity recognition technology, as an important step in constructing knowledge graphs, has been extensively applied in natural language processing applications such as semantic network, machine translation, and question answering systems. It plays a crucial role in promoting the practical application of natural language processing technology. According to the development process of entity recognition technology, the existing entity recognition methods are investigated in this paper. These methods can be classified as: early rule and dictionary based entity recognition methods, machine learning based entity recognition methods, and deep learning-based entity recognition methods. The core ideas, advantages and disadvantages, and representative models of each entity recognition method are summarized, especially the latest entity recognition methods based on Bi-directional Long Short-term Memory (BiLSTM) and Transformer. Additionally, the current mainstream datasets and evaluation criteria are introduced. Finally, facing the semantic requirements of future machine communication, we have summarized the challenges faced by entity recognition technology, and its future advancement in Internet of Things(IoT) business data is anticipated.

Keywords: entity recognition; semantic extraction; deep learning; knowledge graph

实体识别技术^[1]是一种从源数据中提取出专有名词并标注其类型的技术，广泛用于信息提取、信息检索、智能应答系统、机器翻译等众多自然语言处理中。随着工业 4.0 时代的到来，现多采用信息物理系统、物联网和人工智能等实现智能的人机以及机器与机器之间的通信^[2]，知识图谱^[3]应运而生并成为知识工程的代表性产物。

实体识别作为构建知识图谱中基础且关键环节被进一步广泛研究，对其进行阶段性综述是有必要且有意义的。本文调研了现有的各类实体识别方法，根据其发展历程主要分为基于规则和词典的实体识别方法^[4-8]、基于机器学习的命名实体识别方法^[9-13]和基于深度学习的命名实体识别方法^[14-18]，并从模型分类、数据集、评价标准

收稿日期：2023-12-26；修回日期：2024-03-20

基金项目：国家自然科学基金资助项目(U21A20450; 62271266); 江苏省前沿引领技术基础研究专项资助项目(BK20192002; BK20212001)

等方面对已有的研究成果进行综合评述。实际上，机器生成的卫星图像、数字监控、传感器数据等卫星物联网等领域的数据，同样具有较高的冗余性，可以考虑对其进行语义提取及语义通信，达到降低传输量、节省传输能源等目的。因此，本文希望通过分析和总结现有的实体识别方法，对物联网业务数据未来在语义^[19]方面的发展进行展望。

1 实体识别方法

实体识别最初是在 MUC-6(The Sixth of the Series Message Understanding Conference)^[20]上提出的，当时研究的核心是如何在一些领域进行信息抽取，如从报章等非结构化文本中抽取关于机构活动的人名、地名、组织机构名^[21]等核心结构化信息。之后在 MUC-7(The Seventh of the Series Message Understanding Conference)中，实体类别被进一步分为多类：3 大类(实体类、时间类、数字类)和 7 小类(人名、机构名、地名、时间、日期、货币和百分比)^[22]。最早提出的实体识别方法是基于词典和规则匹配的方法^[23]，使用已有的词典或正则表达式等规则对目标文本中的实体进行提取。该方法实现较为简单，但对词典规则的覆盖性要求较高，且无法识别新实体。随着隐马尔可夫模型和条件随机场(Conditional Random Fields, CRF)等概率图模型的提出，实体识别任务有了新的进展：在给定输入序列的情况下对概率进行计算得到标签序列，但该方法对特征有较强依赖。近几年来，循环神经网络(Recurrent Neural Network, RNN)^[24]和双向长短时记忆网络(BiLSTM)^[25]、Transformer 等深度学习模型被运用到实体识别任务中。区别于概率图模型，深度学习模型可以使用低维稠密的矩阵对文本向量进行特征提取，摆脱了对特征工程的依赖。有学者提出将深度学习与概率图模型相结合，如 BiLSTM-CRF 等，通过深度学习模型获取特征信息，使用概率图模型对输出进行语法纠正。实体识别技术的研究进展与分类如图 1 所示。




Fig.1 Classification of the entity recognition

图 1 实体识别技术研究进展与分类

1.1 基于词典和规则匹配的实体识别技术

基于词典和规则的方法是最早用于实体识别的方法，这些方法多运用由语言学专家根据语言知识特性、数据集特征以手工方式构造的规则模板或特殊词典，通过匹配的方式实现实体的识别。规则包括关键词、位置词、方位词、中心词、指示词、统计信息、标点符号等；词典由特征词构成的词典和外部词典共同组成，外部词典指已有的常识词典。

Rau 等^[26]首次提出将人工编写的规则与启发式想法相结合的方法，实现了从文本中自动抽取公司名称类型的命名实体。Shaalan 等^[27]利用文本的上下文特征构造规则，并同时增加地名词典来识别专业名词。闫萍^[7]从实体内部组成和上下文语境入手，针对姓名构建了相应的识别规则，极大提高了中文人名识别的准确率。基于词典和规则的实体识别方法使用简单，结果准确率较高，特别是对于数字和时间、日期实体，利用规则匹配的方式

能获得较好的识别效果。但词典和规则库的建立成本较高，需要花费大量人力资源和时间，而且不同的实体类型需定制不同的规则，不容易在其他实体类型或数据集扩展，移植性差。为解决上述问题，一些专家学者对统计机器学习的实体识别方法进行了研究。

1.2 基于机器学习的实体识别技术

在基于机器学习的方法中，实体识别被看作序列标注问题。在该标注问题中，当前的预测标签不仅与当前的输入特征相关，还与之前的预测标签相关，即预测标签序列之间有强相互依赖关系。基于机器学习的典型实体识别技术有隐马尔可夫模型(Hidden Markov Model, HMM)^[28]、最大熵马尔可夫模型(Maximum Entropy Markov Model, MEMM)^[29]、支持向量机(Support Vector Machine, SVM)模型^[30]和条件随机场(CRF)模型^[31]。基于机器学习的各类实体识别方法对比见表1。

表1 基于机器学习的实体识别方法对比

Table1 Comparison of machine learning-based entity recognition methods

model	principle	advantage	disadvantage
HMM	direct modeling of the transition and performance probabilities, and statistical cooccurrence probabilities	with low time complexity and suitable for small datasets	without considering contextual features, and lower accuracy than MEM
MEMM	establishing joint probability for transition probability and performance probability, and counted conditional probability	higher accuracy than the HMM	high time complexity
SVM	linear classifier with the largest intervals on the feature space	relatively simple, with better robustness	poor performance in large-scale sample training and multi-classification
CRF	statistical global probability, not only in local normalization, but also considering the distribution of data globally	leveraging contextual information	slow convergence speed and high time complexity

1) 基于HMM的实体识别技术

给定一组已知值(输入标记)，HMM可以帮助计算未知变量序列(输出标记)。由于HMM是一个概率图形模型，因此输出标记序列是通过计算输入序列和输出序列之间的概率得出的。HMM的主要目的是尽可能地获得最佳输出标签，因此需要足够多的训练数据消除数据稀疏性问题。但在进行新领域的识别任务时，训练数据往往是不够的。文献[32]中，作者为临床记录中的句子提出了一种语义标记，该语义标记提供了高层次的知识定义。这种基于HMM模型的语义标记可用于挖掘支持决策的知识，但这一系统并不尽如人意，因为它并没有像预期的那样匹配等价类。同时，隐马尔可夫模型只依赖于前一状态及其对应的观测对象，不能考虑上下文之间的关系，在长观测文本中很难获得准确的标签。

2) 基于CRF模型的实体识别技术

CRF是近几年自然语言处理领域常用的算法之一，常用于句法分析、命名实体识别、词性标注等。CRF是在给定观察的标记序列下，计算整个标记序列的联合概率。实际中常用的是线性链CRF，线性链CRF主要有2个重要组成部分：一是发射矩阵部分，参数化表示为各个节点特征函数与其权重的乘积和；另一是转移矩阵部分，参数化表示为各个局部特征函数与其权重的乘积和。每个特征函数的结果都是0/1，这2个部分的组合可以得到非常多不同的发射矩阵和转移矩阵，而其中只有一种组合是正确的(即所需的目标组合)，可以通过SoftMax概率化这个最优结果并取log，即线性链CRF的优化目标就是最大化这个最优组合的概率值。训练完成之后，进行预测时需进行解码，解码使用维特比算法，求解全局最优解，即动态规划。

CRF模型特征灵活，除了语料中的上下文信息等特征，还可以添加外部特征进行辅助，从而获得更多的模型信息。此外，CRF具有很强的推理能力，在训练过程中能够从样本数据中利用特征对数据空间进行划分，得到判别概率。因此，对于特征信息的选择和优化是使用CRF模型能否获得优良结果的关键性因素，特征选择的好与坏将直接决定系统性能的高低。文献[33]结合病案中存在的大量联合实体，制定了复合规则进行标记，在标注语料的基础上，采用CRF算法构建实体识别模型，该模型获得了87.92%的准确率和82.33%的召回率。文献[34]提出了一种基于领域词典和CRF的双层标注模型，该模型在测试集上的宏精确率为96.7%、宏召回率为97.7%、宏F1值为97.2%(需指出：宏指标是指每一类性能指标的算数平均值)。不同于单层CRF宏精确率和宏召回率相差较大的情况，该模型的宏精确率和宏召回率几乎相等，达到了一个很好的平衡。

1.3 基于深度学习的实体识别技术

1) 基于循环神经网络(RNN)模型的实体识别技术

RNN是最早被提出的基于深度学习的命名实体识别方法，RNN的基本结构(如图2所示，图中， X_t 为t时刻隐藏层的输入， h_t 为t时刻隐藏层的输出)很简单，即将网络的输出保存在一个记忆单元中，这个记忆单元和下一

次的输入一起进入神经网络中。RNN 的这种结构使其更适用于解决时间序列问题。




Fig.2 Structure of RNN model
图2 RNN 模型结构

RNN 中神经单元的计算是按时间顺序进行的，前一时刻的神经单元通过数据通路与后一时刻神经单元相连，神经单元之间的数据从一层流入下一层，记忆信息保留的程度通过网络参数进行调整。数据通过重复连接的方式在网络结构内循环，使 RNN 含有记忆功能，在进行实体识别时具有一定优势。

孙悦清等^[35]将协同训练与 RNN 模型相结合完成实体识别任务，并对 RNN 进行改进。实验结果表明，相比传统的 HMM 和 CRF 模型，RNN 更适合做实体识别任务。文献[36]对 RNN 模型进行扩展，以此提高实体识别的性能。文献[37]提出了一种转移式双向递归神经网络。该模型首先在一般领域训练一个浅的双向 RNN，然后从一般领域转移知识来训练一个更深的双向 RNN，以识别来自中国的电子病例系统的医疗概念。

RNN 的设计初衷之一就是能够捕获长距离输入之间的依赖，但根据研究表明，当词项长度超过 500 时，RNN 的识别效果就会变得很差。同时，由于 RNN 在所有隐层共享同一组 W 权值矩阵，梯度在反向传播过程中，数值不是越来越小，就是越来越大，从而导致梯度消失或梯度爆炸。即随着序列长度(即距离)的不断增加，RNN 无法有效地利用历史信息，因此 RNN 无法进行远距离序列标注。针对 RNN 在训练中容易发生梯度爆炸和梯度消失问题，提出了由 RNN 改进而来的长短期记忆网络(Long Short-Term Memory, LSTM)。

2) 基于 LSTM 网络模型的实体识别技术

LSTM 是最早被承认能够有效缓解长期依赖问题的改进方案。LSTM 的隐藏状态计算模块在 RNN 的基础上引入一个新的内部状态：记忆细胞和 3 个控制信息传递的逻辑门：输入门、遗忘门、输出门。LSTM 通过“门”控制丢弃或增加信息，从而实现遗忘或记忆功能。“门”是一种使信息选择性通过的结构，由一个 Sigmoid 函数和一个点乘操作组成。Sigmoid 函数的输出值在 [0,1] 区间，0 代表完全丢弃，1 代表完全通过。其结构如图 3 所示。




Fig.3 LSTM assumption diagram
图3 LSTM 结构图

图 3 中，记忆细胞与隐状态具有相同的形状(向量维度)，目的是用于记录附加的隐藏状态与输入信息，有些文献认为记忆细胞是一种特殊类型的隐状态；输入门管理(本时刻)输入观测和(上时刻)隐藏状态中哪些信息会添

加进记忆细胞；遗忘门管控忘记上时刻记忆细胞中的哪些内容；输出门控制记忆细胞中哪些信息输出给隐藏状态。每个门的计算过程都有当前输入信息与上一时刻的神经单元状态参与，并经过激活函数 \tanh 的非线性映射计算。在 t 时刻，LSTM 的输入分别由上一时刻 LSTM 的隐藏层输出值 H_{t-1} 、当前时刻网络的输入值 X_t 以及上一时刻的单元状态值 C_{t-1} 组成；LSTM 的输出由当前时刻 LSTM 输出值 H_t 和当前时刻的单元状态 C_t 组成。

韩治超等^[38]构建了融合字及笔画特征的 LSTM 进行实体特征提取。使用 LSTM 模型可以更好地捕捉到较长距离的依赖关系，但利用 LSTM 对句子进行建模还存在一个问题：无法编码从后到前的信息，即单向的 LSTM 网络只包含一层正向隐藏层，仅能利用输入序列的单向信息。为获取更好的识别效果，Graves 等^[39]提出利用双向长短时记忆网络(BiLSTM)充分获取正反 2 个方向的信息以获得较优的编码序列。BiLSTM 可以更好地捕捉双向的语义依赖，并避免了 RNN 存在的梯度消失问题，可以存储长时间的有效信息，便于模型更好地完成命名实体识别任务。但如果只使用 BiLSTM 进行序列建模，会导致模型只考虑输入单词序列的信息，而忽略输出标签之间的依赖关系。CRF 的优点就是能对隐含状态建模，通过学习标签之间的相邻关系保证标签的有效性，但缺点是需要手动提取序列特征。因此现阶段实体识别模型多考虑将一些深度学习模型与 CRF 进行结合，以获得两者的优点。在 BiLSTM-CRF 序列标注模型中，使用 BiLSTM 层对输入序列的特征进行集成和提取，它能够输出序列中每个字符对应标签类别的概率分布矩阵；CRF 层能够根据概率分布矩阵找到所有可行序列空间中最合理的序列路径。在 BiLSTM 后添加 CRF 层，对句子序列进行标注和输出，使模型既可以像 CRF 一样考虑序列标签前后之间的关联性，又可以拥有 BiLSTM 的上下文特征抽取及拟合能力。HUANG 等^[40]首次将 BiLSTM-CRF 模型用于自然语言处理基准序列标记数据集，由于模型中采用了双向 LSTM 组件，该模型可以捕捉到当前时刻的过去和未来的特征。实验结果表明 BiLSTM-CRF 模型是稳健的，且对于词嵌入的依赖性较少，但该方法需要大量的特征工程。

3) 基于 Transformer 模型的实体识别技术

Transformer 模型由谷歌于 2017 年提出^[41]，Transformer^[42]是一种基于注意力的机制，旨在解决序列到序列的网络结构。Transformer 是一个 Seq2Seq 模型，其模型架构和大多数神经网络序列模型架构一样，由一个 Encoder 和一个 Decoder 组成。其摒弃了递归和卷积操作，完全依赖于注意力机制，通过多头自注意力机制构建编码层和解码层。编码器由 6 个编码块组成，每个块由自注意力机制和前馈神经网络组成；解码器由 6 个解码块组成，每个块由自注意力机制、encoder-decoder attention 以及前馈神经网络组成。相比于 RNN 和卷积神经网络(CNN)模型，Transformer 具有高度并行化的模型结构，可以解决 RNN 并行计算能力弱的问题。Transformer 模型没有循环结构，能够对序列中的单词或字符进行并行处理，借助注意力机制对序列中所有字或词之间的关系进行建模，以此来解决长期依赖的问题。Transformer 模型结构如图 4 所示。

司逸晨等^[43]提出一种基于 Transformer 编码器的实体识别模型。该模型在 Resume 和 Weibo 中文命名实体识别数据集上的 F1 值分别达到 94.7% 和 58.2%，相比基于 BiLSTM 实体识别模型有所提升，且具有更快的收敛速度。黄子恒等^[44]提出了一种基于 Transformer 的多粒度特征融合的命名实体识别方法。该模型在清华大学公开的数据集上相较于基线模型，F1 值提高了 1.81%~4.27%，精确度提高了 1.78%~4.57%，召回率提高了 1.32%~3.94。这是由于 Transformer 含有多个多头注意力机制，使模型获取到丰富的多层次局部语义特征信息，可以充分结合全局特征和局部特征作出预测，避免了模型只有全局特征可用的问题；此外，在模型的迭代训练阶段加入去噪算法，有效减少中文文本数据中由于人工标注或机器标注出现的噪音数据带来的不良影响，提高了模型的整体效果。

虽然 Transformer 在实体识别任务上取得了非常不错的效果，但该模型也有一定的局限性：a) 简单地抛弃 RNN 和 CNN，Transformer 无法捕获文本序列的局部特征；b) 位置编码并不能改变 Transformer 无法捕获位置信息这一固有的结构缺陷；c) Transformer 的计算和内存开销是序列长度的二次方，该问题在长句中尤其突出。

4) 基于 BERT 模型的实体识别技术

BERT(Bidirectional Encoder Representations from Transformers)模型是一种预训练语言表示学习模型，由 Google 公司的研究人员于 2018 年提出，它基于 Transformer 编码器结构的深度双向模型，只有编码器部分。有学者们发现将 BERT 预训练模型^[45]运用到实体识别研究方法的输入中，可以增强语义表示。具体做法是：对输入的字向量或词向量运用 BERT 预训练模型，再将其与神经网络模型、机器学习模型等结合。实验结果表明，该做法产生了较高的准确率和召回率。文献[46]将 BERT 模型与 BiLSTM 模型、CRF 模型结合以完成识别任务。实验结果表明，随着训练语料库数量的增加，BERT-BiLSTM-CRF 模型的实体识别效果不断提高。WANG 等^[47]使用 BERT 模型对大量未标记的语料库进行无监督学习，然后使用 BiLSTM 模型获得上下文的特征，最后使用 CRF 模型进行预测并完成序列标记。该方法采用《人民日报》作为训练和测试数据，完成识别任务得到的 F1 值为 94.86。文献[48]在同一数据集中对 RNN-CRF、LSTM-CRF、BiLSTM-CRF、BERT-CRF、和 BERT-BiLSTM-CRF 模型进行了测试对比。由于传统 RNN 模型的梯度消失问题，RNN-CRF 模型不能处理长距离依赖关系，F1 值仅为 81.44%；与

RNN-CRF 相比, LSTM-CRF 模型通过添加输入门、遗忘门和输出门来解决梯度消失的问题, 使模型能够获得句子间的关系, F1 值提高为 84.87%; BiLSTM-CRF 模型相较于 LSTM-CRF 模型, 能够捕捉句子双向的语义关系, F1 值达到 87.18%; 而在 BERT-BiLSTM-CRF 模型中, BERT 预训练模型可以并行获得全局信息, 其 F1 值提高至 93.05%。由此可见, BERT 预训练模型与其他神经网络模型或机器学习模型等结合, 可以更好地完成实体识别任务。表 2 为 Transformer 模型与 BERT 模型的对比。




Fig.4 Structure of transformer model

图 4 Transformer 模型结构

表 2 Transformer 模型与 BERT 模型的对比

Table 2 Transformer model vs. BERT model

	BERT model	Transformer model
model structure	BERT is a model based on the Transformer encoder structure with only the Encoder part.	Transformer is a model of the complete sequence-to-sequence structure consisting of Encoder and Decoder.
pretrain corpus	BERT uses an extensive and unsupervised pretraining corpus; a richer semantic knowledge can be learned.	Transformer usually uses a supervised parallel corpus, which yields more specialized and targeted knowledge.
weights	BERT uses the same parameters for multi-layer Transformer encoder stacking, weights are shared and the model is more concise.	Transformer's encoder and decoder have different parameters, weights are not shared, and the model is relatively more complex.

5) 基于迁移学习的实体识别技术

迁移学习是深度学习前沿的研究领域, 许多学者利用深度学习技术构建迁移学习模型, 其主要思想是将相关领域所学到的知识结构迁移到目标领域, 核心是探索把已标注的数据集源领域知识迁移到将要学习的新数据集目标领域上, 提高目标领域实体识别任务的效果^[49]。迁移学习模型结构如图 5 所示, 该方法多适用于存在资源匮乏、实体类型多样等问题的目标领域。目前的研究中存在两种类型的迁移学习策略: 一种是将预训练模型作为特征提取器, 利用预训练模型来提取其他任务的特征; 另一种策略是对预训练模型进行微调以适应目标源。该方法适用于相同的标签集和不同标签集的传输。

文献[50]中提出了一种基于 Transformer 的迁移学习模型, 该模型由文本表示、特征提取和序列标注 3 层结构

组成。实验验证该基于迁移学习的模型可以提高小范围标记样本实体识别的准确性。文献[51]中提出了一种基于多任务和迁移学习的实体识别方法。该模型的F1分数在单个数据集的精确度提高了3.5%以上，且在长尾数据集和小尺寸数据集上仍取得了很好的F1分数。YU Xin等^[52]实现了基于谷歌BERT的BioBERT模型，并在医学领域对BioBERT模型进行预训练，将文本转化为一个数值向量。该方法提高了电子病历的实体识别效率，并将F1评分提高到87.10%。KANG等^[53]构建了基于迁移学习的神经网络模型，结合自注意力机制和独立循环神经网络以捕捉句子的整体依赖性，实验表明该模型的F1评分均值为90.57%，优于基线模型，进一步提高了实体识别效果。迁移学习模型能够利用源域的数据将共性特征迁移至全新的、缺乏标注语料的目标域，可有效解决有监督学习依赖数据集的问题，提高了模型的有效性和可移植性。同时，迁移学习模型为新兴领域提供了基础信息支持，能够在少量人工标注语料上获得较好的实体识别效果，实现对现有数据的充分利用。各种方法总结与对比如表3所示。

2 数据集

目前主流的实体识别数据集有：MSAR^[54]、Weibo^[55]、OntoNotes 4.0^[56]、Resume^[57]、OntoNotes 5.0^[58]、CLUENER2020^[59]。MSRA数据集是由微软亚洲研究院(Microsoft Research Asia, MSRA)提供的面向新闻领域的数据集，MSRA数据集包含4万多条训练集和4千多条测试集，实体类型包括地名、人名、组织名。Weibo是一个基于微博消息的数据集，其中包括人名、组织名、地名、时间、日期、专业术语等多种实体类型。OntoNotes 4.0包含了中英文的新闻专线、广播专线、广播对话和Web数据以及阿拉伯语的新闻专线数据，其中所含中文数据为：250 k字的新闻专线、250 k字的广播新闻、150 k字的广播对话和150 k字的网络文本。Resume是通过收集新浪财经网上关于中国股市上市公司的高管简历，并经过人工标注和过滤筛选所组成，Resume数据集包含了1 027份简历，并含有人名、国籍、籍贯、种族、专业、学位、机构、职称等8种实体类型。OntoNotes 5.0则在OntoNotes 4.0的基础上添加了100 k字的电话交谈数据。CLUENER2020是由CLUE^[60](Chinese Language Understanding Evaluation)组织建立的一个NER数据集，CLUENER2020包含地址、书名、公司、游戏、政府、电影、姓名、组织机构、职位、景点10种实体类型。

3 评价指标

目前，实体识别常采用的评价指标有3种：准确率(Precision, P)、召回率(Recall, R)、F1值(F1-Measure, F1)。

准确率：对给定数据集，模型正确识别的实体个数与模型识别出的实体个数的比值，即：

$$P = \frac{P_T + N_T}{P_T + N_F + P_F + N_T} \quad (1)$$

式中： P_T 表示被模型预测为正例的正样本； P_F 表示被模型预测为正例的负样本； N_F 表示被模型预测为负例的正样本； N_T 表示被模型预测为负例的负样本。

召回率：模型正确标注的实体个数与输入样本实体个数的比值，即：

$$R = \frac{P_T}{P_T + N_F} \quad (2)$$

F1值：是精确率和召回率的调和平均指标，是平衡准确率和召回率影响的综合指标。

$$F1 = \frac{2PR}{P+R} \times 100\% \quad (3)$$

精确率和召回率两者的取值都在0和1之间，数值越接近1，精确率或召回率就越高。但精确率和召回率有




Fig.5 Structure of the transfer learning model

图5 迁移学习模型结构

时会出现矛盾，这需要综合考虑它们的加权调和平均值，即 F1 值。F1 值较高，说明试验方法越有效。表 4~7 给出了不同数据集在不同模型上的准确率、召回率及 F1 值得分对比。

表3 各实体识别方法总结与对比
Table3 Summary and comparison of various entity recognition methods

method	characteristic	advantage	disadvantage
rule and dictionary based named entity recognition methods	Relying on pre-built dictionaries and rules. It is simple and easy to implement and does not require a large amount of labeled data.	This method allows for exact matching of specific entities. It applies to specialized areas or limited classes of entities.	The generalization ability is limited for scenarios with unknown entities and significant changes in language structure. In addition, a large amount of manual construction and maintenance of dictionaries and rules are required.
HMM	HMM is a generative model based on state transition probability and observation probability.	HMM can capture the probability distribution of sequence data. For situations with limited annotated data, good results can still be achieved.	HMM finds it difficult to handle long-term dependency relationships. Moreover, the ability to understand complex sequence data and semantics is weak.
CRF	CRF is a discriminative model based on Markov properties. It can model the dependency relationships between features.	CRF can achieve good results when there is sufficient annotated data. This model can flexibly design feature functions to meet different task requirements.	The ability to model long-distance dependencies is limited. In addition, the estimation of model parameters requires a large amount of annotated data.
RNN	RNN is a neural network structure with recurrent connections. It can process sequence data and preserves the historical information of the sequence.	RNN can capture contextual information in sequence data. It has good adaptability for situations where the sequence length is not fixed.	RNN is difficult to parallelize and has a slow training speed. Moreover, problems of gradient disappearance or explosion are prone to occur, making training difficult.
LSTM	LSTM is a special RNN structure with memory units and gating mechanisms. It can more effectively solve the modeling problem of long sequence data.	The LSTM model effectively overcomes the vanishing and exploding gradient problems of RNN.	There are many parameters, and training and tuning are more complex. In addition, limitations still exist when dealing with extremely long sequence data.
BiLSTM	BiLSTM considers both forward and backward information of sequence data.	Bidirectional information can be utilized effectively, and contextual information of sequence data can be captured more comprehensively.	The calculation complexity is high and the number of parameters is large. For some tasks, bidirectional information may introduce noise.
Transformer	Transformer is a model based on a self-attention mechanism that does not depend on the sequence order.	It can parallelize the processing of sequential data. The training and reasoning process can be accelerated.	The number of parameters is large and requires more computing resources.
BERT	BERT is based on the Transformer structure and pre-trains the language representation with bi-directional context information. It can be used directly for fine-tuning a variety of entity recognition tasks.	BERT has multitasking applicability. And as an end-to-end model, there is no need to manually design features or rules, and it can automatically learn the representation in the text. Artificial intervention and complexity have been reduced.	The pre-training and fine-tuning process requires significant computational resources and time. Text that exceeds the maximum length limit needs to be truncated or segmented, which may affect the performance of the model.
Transfer learning	Transfer learning uses source domain data or knowledge to solve tasks in the target domain. Existing data can be utilized efficiently and the need for targeted domain labeled data can be reduced.	It can still achieve better results when the target domain data is scarce or difficult to label. In addition, transfer learning can accelerate the model training process and improve the generalization ability of the model.	This method has strong dependence on the source domain data and may introduce the bias of the source domain. Transfer learning strategies need to be carefully designed to balance the differences between the source domain and the target domain.

表4 数据集 MSRA 的结果比较(%)

Table4 Results on MSRA(%)

model	P	R	F1
TENER ^[61] (2019)	-	-	92.74
Sui et.al ^[62] (2019)	94.01	92.93	93.47
FGN ^[63] (2020)	95.45	95.81	95.64
MECT ^[64] (2021)	94.55	94.09	94.32
W ² NER ^[65] (2022)	96.12	96.08	96.10
SSMI ^[66] (2023)	96.15	96.49	96.32

表5 数据集 Weibo 的结果比较

Table5 Results on Weibo

model	precision	recall	F1
TENER ^[61] (2019)	-	-	58.17
LGN ^[67] (2019)	55.34	64.98	60.21
FLAT ^[68] (2020)	-	-	60.32
FGN ^[63] (2020)	69.02	73.65	71.25
MECT ^[64] (2021)	61.91	62.51	63.30
NFLAT ^[69] (2022)	59.10	63.76	61.94
W ² NER ^[65] (2022)	70.84	73.87	72.32
SSMI ^[66] (2023)	71.53	73.18	72.83

表6 数据集OntoNote4.0的结果比较

Table6 Results on OntoNote4.0

model	P	R	F1
TENER ^[61] (2019)	—	—	72.43
LGN ^[67] (2019)	76.13	73.68	74.89
AESINER ^[70] (2020)	—	—	81.18
FGN ^[63] (2020)	82.61	81.48	82.04
MECT ^[64] (2021)	77.57	76.27	76.92
Baseline ^[71] (2022)	82.79	81.27	82.03
W ² NER ^[65] (2022)	82.31	82.31	83.08
SSMI ^[66] (2023)	82.46	84.61	83.52

表7 数据集Resume的结果比较

Table7 Results on Resume

model	P	R	F1
CAN-NER ^[72] (2019)	95.05	94.82	94.94
TENER ^[61] (2019)	—	—	95.00
LGN ^[67] (2019)	95.28	95.46	95.37
SLK-NER ^[73] (2020)	95.20	96.40	95.80
FGN ^[63] (2020)	96.49	97.08	96.79
MECT ^[64] (2021)	96.40	95.39	95.89
W ² NER ^[65] (2022)	96.96	96.35	96.35
SSMI ^[66] (2023)	97.48	97.18	97.33

4 结论

本文对实体识别的相关方法进行了梳理与总结，并对基于深度学习的实体识别方法中较常用的模型BiLSTM-CRF模型、Transformer模型进行了详细研究；最后对实体识别的数据集和评价指标进行说明。目前，随着实体识别技术的日渐成熟，实体识别在金融、医疗、法律等多文本记录的垂直领域有着越来越广泛的应用。事实上，诸如卫星物联网等领域的卫星图像、数字监控、传感器数据等类型数据，同样具有较高的冗余度，可以考虑进行语义提取及语义通信，以达到降低传输量、节省传输能源等目的。但目前尚未有可直接适用于物联网业务数据的实体识别方法，因此依然需要研究人员投入大量精力进行不断探索，这也对未来实体识别技术的发展提出了新的方向及要求。

1) 非结构化数据的处理。现有基于深度学习的实体识别方法在新闻类、医疗等规范文本上的识别F1值已达到了较高水平，但在一些非正式文本上，F1值最高仅为68.55%。对于卫星图像、勘测数据、监控图像和视频、传感器数据等典型机器生成类非结构化数据，相比于规范文本，存在篇幅较短，数据零散，特征稀疏等特点。因此，如何对该类数据进行快速且高效的语义提取，降低知识冗余度，将是未来的研究方向之一。

2) 融合专业知识。特定的专业知识往往可以提高实体识别的准确率，特别是在卫星物联网这种垂直领域的实体识别任务，对于一些罕见特征，结合特定的领域背景才能够准确理解其含义。因此，在进行卫星物联网领域的实体识别任务时，可以通过领域专家介入，融合专业知识和专家经验，加强未登录词的检测和指定多样化的实体识别规则，以提升实体识别的效果。

3) 多任务学习。使用多个有关联的任务中的有用信息帮助每一个任务得到更为准确的学习器。根据实体识别的定义，实体识别本身就可分解为2个任务来学习：一个是实体边界识别；另一个是实体类型识别。可以考虑将实体识别任务与其他处理任务结合，如在知识图谱的构建过程中，可考虑将实体识别任务与关系抽取任务结合进行关联抽取，以节省模型训练时间以及人工参与的复杂度；或考虑将实体识别任务与实体消歧任务联合进行，因为实体消歧不仅有助于成功检测实体边界，而且对实体类型的正确分类也有帮助。

参考文献：

- [1] LI Jing, SUN Aixin, HAN Jianglei, et al. A survey on deep learning for named entity recognition[J]. IEEE Transactions on Knowledge and Data Engineering, 2022,34(1):50–70. doi:10.1109/TKDE.2020.2981314.
- [2] GONZALEZ G L. A knowledge graph based integration approach for industry 4.0[D]. Nordrhein-Westfalen:Universität Bonn, 2019.
- [3] LI Chenxi, HE Wenji, YAO Haipeng, et al. Knowledge graph aided network representation and routing algorithm for Leo satellite networks[J]. IEEE Transactions on Vehicular Technology, 2023,72(4):5195–5207. doi:10.1109/TVT.2022.3225666.
- [4] KIM J H, WOODLAND P C. A rule-based named entity recognition system for speech input[C]// Proceedings of the 6th International Conference on Spoken Language Processing(ICSPL). Beijing, China:[s. n.], 2000: 528–531. doi: 10.21437/ICSPL.2000-131.
- [5] QUIMBAYA A P, SIERRA M A, GONZALEA RIVERA Q A. Named entity recognition over electronic health records through a combined dictionary-based approach[J]. Procedia Computer Science, 2016(100):55–61.
- [6] HUANG Zhiheng, XU Wei, YU Kai. Bidirectional LSTM-CRF models for sequence tagging[DB/OL]. [2023-12-26]. <https://arxiv.org/abs/1508.01991>.
- [7] 闫萍. 基于规则和概率统计相结合的中文命名实体识别研究[J]. 计算机与数字工程, 2011,39(9):88–91. (YAN Ping. Research on the identification for Chinese named entity based on combination of rules and statistic analysis[J]. Computer and Digital Engineering, 2011,39(9):88–91.) doi:10.3969/j.issn.1672–9722.2011.09.025.

- [8] YI Feng, JIANG Bo, WANG Lu, et al. Cybersecurity named entity recognition using multi-modal ensemble learning[J]. IEEE Access, 2020(8):63214–63224. doi:10.1109/ACCESS.2020.2984582.
- [9] 王欢,朱文球,吴岳忠,等. 基于数控机床设备故障领域的命名实体识别[J]. 工程科学学报, 2020,42(4):476–482. (WANG Huan,ZHU Wenqiu,WU Yuezhong,et al. Named entity recognition based on equipment and fault field of CNC machine tools[J]. Chinese Journal of Engineering, 2020,42(4):476–482.) doi:10.13374/j.issn2095-9389.2019.09.17.002.
- [10] LAFFERTY J D,MCCALLUM A,PEREIRA F C N. Conditional random fields:probabilistic models for segmenting and labeling sequence data[C]// Proceedings of the Eighteenth International Conference on Machine Learning. Williamstown, America: Morgan Kaufmann Publishers Inc, 2001:282–289. doi:10.5555/645530.655813.
- [11] SAMPATHKUMAR H, CHEN Xuwen, LUO Bo. Mining adverse drug reactions from online healthcare forums using hidden Markov model[J]. BMC Medical Informatics and Decision Making, 2014(14):91. doi:10.1186/1472-6947-14-91.
- [12] HANNA M W. Conditional random fields:an introduction:MS–CIS–04–21[R]. Philadelphia:University of Pennsylvania, 2004.
- [13] 王江伟. 基于最大熵模型的中文命名实体识别[D]. 南京:南京理工大学, 2005. (WANG Jiangwei. Chinese named entity recognition based on maximum entropy model[D]. Nanjing,China:Nanjing University of Technology,Nanjing, 2005.) doi:10.7666/d.Y763193.
- [14] EMMA S,PATRICK V,DAVID B. Fast and accurate entity recognition with iterated dilated convolutions[C]// Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing. Copenhagen, Denmark: ACL, 2017: 2670–2680. doi:10.18653/v1/D17-1283.
- [15] LIU Wei,XU Tongge,XU Qinghua. 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. Minneapolis,Minnesota:ACL, 2019:2379–2389. doi:10.18653/v1/N19-1247.
- [16] XU Yongxiu, HUANG Heyang, FENG Chong, et al. A supervised multi-head self–attention network for nested named entity recognition[J]. AAAI Conference on Artificial Intelligence, 2021,35(16):14185–14193. doi:<https://doi.org/10.1609/aaai.v35i16.17669>.
- [17] 边俐菁. 基于深度学习和远程监督的产品实体识别及其领域迁移研究[D]. 上海:上海财经大学, 2020. (BIAN Lijing. Research on product entity recognition and domain migration based on deep learning and remote supervision[D]. Shanghai, China:Shanghai University of Finance and Economics, 2020.)
- [18] YANG Zhiwei, MA Jing, CHEN Hechang. HiTRANS:a hierarchical transformer network for nested named entity recognition[C]// Proceedings of the Findings of the Association for Computational Linguistics. Punta Cana,Dominican Republic:ACL, 2021:124–132. doi:10.18653/v1/2021.findings-emnlp.12.
- [19] LAKKA E, PETROULAKIS N E, HATZIVASILIS G, et al. End-to-end semantic interoperability mechanisms for IoT[C]// 2019 IEEE 24th International Workshop on Computer Aided Modeling and Design of Communication Links and Networks(CAMAD). Limassol,Cyprus:IEEE, 2019:1–6. doi:10.1109/CAMAD.2019.8858501.
- [20] RALPH G, BETH S. Message understanding conference–6: a brief history[C]// Proceedings of the 16th Conference on Computational Linguistics–Volume 1. Copenhagen Denmark:ACL, 1996:466–471. doi:10.3115/992628.992709.
- [21] 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 Hui,PANG Haiting,FENG Shanshan,et al. Summary of Chinese named entity recognition technology[J]. Journal of Changchun University of Technology(Natural Science Edition), 2021,42(5):444–450.) doi:10.15923/j.cnki.cn22-1382/t.2021.5.10.
- [22] 江千军,桂前进,王磊,等. 命名实体识别技术研究进展综述[J]. 电力信息与通信技术, 2022,20(2):15–24. (JIANG Qianjun, GUI Qianjin, WANG Lei,et al. A review of the research progress of named entity recognition[J]. Electric Power Information and Communication Technology, 2022,20(2):15–24.) doi:10.16543/j.2095-641x.electric.power.ict.2022.02.003.
- [23] 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 Shudong, OUYANG Xiaoye. Overview of named entity recognition technology[J]. Radio Communications Technology, 2020,46(3): 251–260. doi: 10.3969/j. issn.1003-3114.2020.03.001.
- [24] ALI S, MASOOD K, RIAZ A, et al. Named entity recognition using deep learning:a review[C]// 2022 International Conference on Business Analytics for Technology and Security(ICBATS). Dubai,United Arab Emirates:IEEE, 2022:1–7. doi:10.1109/ICBATSS54253.2022.9759051.
- [25] QIN Minghe, WANG Qinglin, LI Yuan. Research on entity mention recognition based on LSTM[C]// 2019 Chinese Control Conference(CCC). Guangzhou,China:IEEE, 2019:8712–8717. doi:10.23919/ChiCC.2019.8866207.
- [26] RAU L F. Extracting company names from text[C]// Proceedings the Seventh IEEE Conference on Artificial Intelligence Application. Miami Beach,FL,USA:IEEE, 1991:29–32. doi:10.1109/CAIA.1991.120841.

- [27] SHAALAN K, RAZA H. NERA:Named Entity Recognition for Arabic[J]. Journal of the American Society for Information Science and Technology, 2009,60(8):1652–1663. doi:10.5555/1572678.1572692.
- [28] 俞鸿魁,张华平,刘群,等. 基于层叠隐马尔可夫模型的中文命名实体识别[J]. 通信学报, 2006,27(2):87–94. (YU Hongkui, ZHANG Huaping, LIU Qun, et al. Chinese named entity identification using cascaded hidden Markov model[J]. Journal on Communications, 2006,27(2):87–94.) doi:10.3321/j.issn:1000–436X.2006.02.013.
- [29] 李诺,张全. 基于概念属性特征的中文地名识别处理[C]// 中国计算机语言学研究前沿进展(2007–2009). 北京:清华大学出版社, 2009:579–584. (LI Nuo, ZHANG Quan. Conceptual attribute-based feature recognition processing for Chinese geographical names[C]// Progress on the Frontiers of Computational Linguistics Research in China(2007–2009). Beijing, China: Tsinghua University Press, 2009:579–584.)
- [30] 李丽双,黄德根,陈春荣,等. 基于支持向量机的中文文本中地名识别[J]. 大连理工大学学报, 2007,47(3):433–438. (LI Lishuang, HUANG Degen, CHEN Chunrong, et al. Identification of location names from Chinese texts based on support vector machine[J]. Journal Of Dalian University Of Technology, 2007,47(3):433–438.) doi:10.3321/j.issn:1000–8608.2007.03.025.
- [31] 黄水清,王东波,何琳. 基于先秦语料库的古汉语地名自动识别模型构建研究[J]. 图书情报工作, 2015,59(12):135–140. (HUANG Shuiqing, WANG Dongbo, HE Lin. Research on constructing automatic recognition model for ancient Chinese place names based on Pre–Qin corpus[J]. Library and Information Service, 2015,59(12):135–140.) doi:10.13266/j.issn.0252–3116. 2015.012.020.
- [32] JANG H, SONG S K, MYAENG S H. Text mining for medical documents using a hidden Markov model[C]// Information Retrieval Technology. [S.l.]:Springer Berlin Heidelberg, 2006:553–559. doi:10.1007/11880592_45.
- [33] LI Yong, MA Qixian, WANG Xia. Medical text entity recognition based on CRF and joint entity[C]// 2021 IEEE Asia–Pacific Conference on Image Processing, Electronics and Computers. Dalian, China: IEEE, 2021: 14–16. doi: 10.1109/IPEC51340. 2021.9421264.
- [34] 龚乐君,张知菲. 基于领域词典与CRF双层标注的中文电子病历实体识别[J]. 工程科学学报, 2020,42(4):469–475. (GONG Lejun, ZHANG Zhifei. Clinical named entity recognition from Chinese electronic medical records using a double-layer annotation model combining a domain dictionary with CRF[J]. Chinese Journal of Engineering, 2020,42(4):469–475.) doi: 10.13374/j.issn2095–9389.2019.09.04.004.
- [35] 孙悦清. 基于循环神经网络RNN的领域命名实体识别方法研究[D]. 武汉:武汉理工大学, 2018. (SUN Yueqing. Research on domain named entity recognition method based on recurrent neural network RNN[D]. Wuhan, China: Wuhan University of Technology, 2018.)
- [36] LI Lishuang, JIN Liuke, JIANG Zhenchao, et al. Biomedical named entity recognition based on extended Recurrent Neural Networks[C]// 2015 IEEE International Conference on Bioinformatics and Biomedicine(BIBM). Washington, DC, USA: IEEE, 2015:649–652. doi:10.1109/BIBM.2015.7359761.
- [37] DONG Xishuang, CHOWDHURY S, QIAN Lijun, et al. Transfer Bi–directional LSTM RNN for named entity recognition in Chinese electronic medical records[C]// 2017 IEEE the 19th International Conference on e–Health Networking, Applications and Services(Healthcom). Dalian, China:IEEE, 2017:1–4. doi:10.1109/HealthCom.2017.8210840.
- [38] 韩治超. 基于深度学习的电子病历实体识别研究[D]. 秦皇岛:燕山大学, 2021. (HAN Zhichao. Research on entity recognition of electronic medical records based on deep learning[D]. Qinhuangdao, Shandong, China: Yanshan University, 2021.)
- [39] GRAVES A, SCHMIDHUBER J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures[J]. Neural Networks, 2005,18(5–6):602–610.
- [40] HUANG Zhiheng, XU Wei, YU Kai. Bidirectional LSTM–CRF models for sequence tagging[DB/OL]. [2023–12–26]. <https://arxiv.org/abs/1508.01991>.
- [41] ASHISH V, NOAM S, NIKI P. Attention is all you need[DB/OL]. [2023–12–26]. <https://arxiv.org/abs/1706.03762>.
- [42] TONG Weiyue. Named entity recognition of power communication planning based on transformer[C]// 2022 IEEE the 10th Joint International Information Technology and Artificial Intelligence Conference(ITAIC). Chongqing, China: IEEE, 2022:588–592. doi: 10.1109/ITAIC54216.2022.9836600.
- [43] 司逸晨,管有庆. 基于Transformer编码器的中文命名实体识别模型[J]. 计算机工程, 2022,48(7):66–72. (SI Yichen, GUAN Youqing. Chinese named entity recognition model based on transformer encoder[J]. Computer Engineering, 2022,48(7):66–72.) doi:10.19678/j.issn.1000–3428.0061432.
- [44] 黄子恒. 基于Transformer的命名实体识别方法及应用研究[D]. 重庆:重庆邮电大学, 2021. (HUANG Ziheng. Research on transformer based named entity recognition method and application[D]. Chongqing, China: Chongqing University of Posts and Telecommunications, 2021.)

- [45] DEVLIN J, CHANG Mingwei, LEE K. 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. Minneapolis, Minnesota:ACL, 2019:4171–4186. doi:10.18653/v1/N19-1423.
- [46] LI Hui, YU Lin, LYU Ming, et al. Fusion deep learning and machine learning for multi-source heterogeneous military entity recognition[C]// 2021 IEEE Conference on Telecommunications, Optics and Computer Science(TOCS). Shenyang, China:IEEE, 2021:535–539. doi:10.1109/TOCS53301.2021.9688813.
- [47] 王子牛,姜猛,高建瓴,等. 基于BERT的中文命名实体识别方法[J]. 计算机科学,2019,46(2):138–142. (WANG Ziniu,JIANG Meng,GAO Jianling,et al. Chinese named entity recognition method based on BERT[J]. Computer Science, 2019,46(2):138–142.) doi:CNKI:SUN:JSJA.0.2019-S2-030.
- [48] HU Jiangyi, YANG Wenqing, YANG Huafei, et al. Named entity recognition method for power equipment based on BERT-BiLSTM-CRF[C]// 2022 IEEE Intl Conf on Dependable, Autonomic and Secure Computing,Intl Conf on Pervasive Intelligence and Computing,Intl Conf on Cloud and Big Data Computing,Intl Conf on Cyber Science and Technology Congress(DASC/PiCom/CBDCom/CyberSciTech). Falerna, Italy:IEEE, 2022:1–6. doi:10.1109/DASC/PiCom/CBDCom/Cy55231.2022.9927964.
- [49] EGAN T M, YANG Baiyin, BARTLETT K R. The effects of organizational learning culture and job satisfaction on motivation to transfer learning and turnover intention[J]. Human Resource Development Quarterly, 2004, 15(3):279–301. doi: 10.1002/hrdq.1104.
- [50] NA Qionglan, SU Dan, ZHANG Jiaojiao, et al. A transfer learning based model for knowledge graph in power grid[C]// 2022 the 4th International Academic Exchange Conference on Science and Technology Innovation(IAECST). Guangzhou, China: IEEE, 2022:1524–1527. doi:10.1109/IAECST57965.2022.10061887.
- [51] GUO Wenming, LU Junda, HAN Fang. Named entity recognition for Chinese electronic medical records based on multitask and transfer learning[J]. IEEE Access, 2022(10):77375–77382. doi:10.1109/ACCESS.2022.3192866.
- [52] YU Xin, HU Wenshen, LU Sha, et al. BioBERT based named entity recognition in electronic medical record[C]// 2019 the 10th International Conference on Information Technology in Medicine and Education(ITME). Qingdao, China: IEEE, 2019:49–52. doi: 10.1109/ITME.2019.00022.
- [53] KANG Keming, TIAN Shengwei, YU Long. Named entity recognition of local adverse drug reactions in Xinjiang based on transfer learning[J]. Journal of Intelligent & Fuzzy Systems, 2021, 40(5):8899–8914. doi:10.3233/JIFS-201017.
- [54] GINA A L. The third international Chinese language processing bakeoff: word segmentation and named entity recognition[C]// Proceedings of the Fifth SIGHAN Workshop on Chinese Language Processing. Sydney, Australia: ACL, 2006:108–117.
- [55] PENG Nanyuan, 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. Lisbon, Portugal: ACL, 2015:548–554. doi:10.18653/v1/D15-1064.
- [56] RALPH W, MARTHA P, MITCHELL M. Ontonotes release 4.0[M]. Philadelphia: Linguistic Data Consortium, 2011. doi: org/10.35111/gfjf-7r50.
- [57] ZHANG Yue, YANG Jie. Chinese NER using lattice LSTM[C]// Proceedings of the 56th Annual Meeting of Association for Computational Linguistics. Melbourne, Australia: ACL, 2018:1554–1564. doi:10.18653/v1/P18-1144.
- [58] RALPH W, MARTHA P, MITCHELL M. Ontonotes release 5.0[M]. Philadelphia: Linguistic Data Consortium, 2013. doi: org/10.35111/xmhb-2b84.
- [59] XU Liang, DONG Qianqian, LIAO Yixuan, et al. CLUENER2020:fine-grained named entity recognition dataset and benchmark for Chinese[DB/OL]. [2023-12-26]. <https://arxiv.org/abs/2001.04351>.
- [60] XU Liang, HU Hai, ZHANG Xuanwei, et al. Clue:a Chinese language understanding evaluation benchmark[DB/OL]. [2023-12-26]. <https://arxiv.org/abs/2004.05986>.
- [61] YAN Hang, DENG Bocao, LI Xiaonan, et al. Tener: adapting transformer encoder for named entity recognition[DB/OL]. [2023-12-26]. <https://arxiv.org/abs/1911.04474>.
- [62] SUI Dianbo, CHEN Yubo, LIU Kang, et al. Leverage lexical knowledge for Chinese named entity recognition via collaborative graph network[C]// Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. Hong Kong, China: ACL, 2019: 3830–3840. doi: 10.18653/v1/D19-1396.
- [63] XUAN Zhenyu, BAO Rui, JIANG Shengyi. FGN:Fusion Glyph Network for Chinese named entity recognition[C]// Knowledge Graph and Semantic Computing: Knowledge Graph and Cognitive Intelligence. Singapore: Springer, 2021: 28–40. doi: 10.1007/978-981-16-1964-9_3.

- [64] WU Shuang, SONG Xiaoming, FENG Zhenhua. MECT: Multi-metadata Embedding based Cross-Transformer for Chinese named entity recognition[C]// Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. [S. l.]: ACL, 2021: 1529–1539. doi: 10.18653/v1/2021.acl-long.121.
- [65] LI Jingye, FEI Hao, LIU Jiang, et al. Unified named entity recognition as word-word relation classification[C]// Proceedings of the 36th AAAI Conference on Artificial Intelligence. Virtual, Online: Association for the Advancement of Artificial Intelligence, 2022: 10965–10973. doi:https://doi.org/10.1609/aaai.v36i10.21344.
- [66] QI Pengnian, QIN Biao. SSMI: Semantic Similarity and Mutual Information maximization based enhancement for Chinese NER [C]// Proceedings of the AAAI Conference on Artificial Intelligence. Washington, DC, USA:[s.n.], 2023: 1–9. doi:https://doi.org/10.1609/aaai.v37i11.26580.
- [67] GUI Tao, ZOU Yicheng, ZHANG Qi, et al. A lexicon-based graph neural network for Chinese NER[C]// Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. Hong Kong, China: Association for Computational Linguistics, 2019: 1040–1050. doi: 10.18653/v1/D19-1096.
- [68] LI Xiaonan, YAN Huang, QIU Xipeng, et al. FLAT: Chinese NER using flat-lattice transformer[DB/OL]. [2023-12-26]. <https://arxiv.org/abs/2004.11795>.
- [69] WU Shuang, SONG Xiaoning, FENG Zhenhua, et al. NFLAT: non-flat-lattice transformer for Chinese named entity recognition [DB/OL]. [2023-12-26]. <https://arxiv.org/abs/2205.05832>.
- [70] NIE Yuyang, TIAN Yuanhe, SONG Yan, et al. Improving named entity recognition with attentive ensemble of syntactic information [DB/OL]. [2023-12-26]. <https://arxiv.org/abs/2010.15466>.
- [71] ZHU Enwei, LI Jinpeng. Boundary smoothing for named entity recognition[DB/OL]. [2023-12-26]. <https://arxiv.org/abs/2204.12031>.
- [72] ZHU Yuying, WANG Guoxin, KARLSSON B F. CAN-NER: convolutional attention network for Chinese named entity recognition [DB/OL]. [2023-12-26]. <https://arxiv.org/abs/1904.02141>.
- [73] HU Dou, WEI Lingwei. SLK-NER: exploiting second-order lexicon knowledge for Chinese NER[DB/OL]. [2023-12-26]. <https://arxiv.org/abs/2007.08416>.

作者简介：

马艺洁(2000-), 女, 在读硕士研究生, 主要研究方向为卫星通信. email:ML815825@163.com.

赖海光(1975-), 男, 博士, 教授, 主要研究方向为卫星通信.

刘子威(1989-), 男, 博士, 副教授, 主要研究方向为卫星通信.

杨楠(2001-), 男, 在读硕士研究生, 主要研究方向为卫星通信.

张更新(1967-), 男, 博士, 教授, 博士生导师, 主要研究方向为天地一体化网络、卫星物联网.

(上接第502页)

- [24] 魏秀业,潘宏侠. 粒子群算法及智能故障诊断[M]. 北京:国防工业出版社, 2010.(WEI Xiuye, PAN Hongxia. Particle swarm optimization and intelligent fault diagnosis[M]. Beijing:National Defense Industry Press, 2010.)

作者简介：

徐阳威(1998-), 男, 在读硕士研究生, 主要研究方向为卫星通信. email:1021010301@njupt.edu.cn.

张晨(1985-), 男, 博士, 高级工程师, 主要研究方向为天地一体化网络、卫星资源分配.

张更新(1967-), 男, 博士, 教授, 博士生导师, 主要研究方向为天地一体化网络、卫星物联网.