

# 基于证据理论和局部语义区分的嵌套命名实体识别

徐波波<sup>1</sup>, 叶娜<sup>1</sup>, 蒋明翀<sup>1\*</sup>,  
<sup>1</sup>沈阳航空航天大学 计算机学院  
xubobo@stu.sau.edu.cn, yena\_1@126.com  
jiangming2@stu.sau.edu.cn

## 摘要

嵌套命名实体识别(NER)是自然语言处理中一个基本任务,其目的是通过计算机辅助技术识别并提取嵌套实体及其对应语义类型。目前嵌套命名实体识别的主流研究方法是基于跨度的方法,该方法将实体识别视为一个跨度分类任务,可以有效地处理嵌套实体。然而,基于跨度的嵌套命名实体识别方法无法准确区分相似实体之间的细微语义区别。并且通过枚举的方式会产生大量噪声跨度,影响模型性能。针对上述问题,本文提出一种方法,既能够量化模型预测的不确定性,通过不确定性辅助模型的推理,降低噪声跨度对模型性能的影响,还能通过局部语义区分模块区分出实体间的语义区别。具体来说,针对噪声跨度对模型性能产生影响的问题,本文设计了一种不确定度引导的KNN辅助决策机制,用于在不确定性较高时对预测结果进行校正。此外,针对嵌套命名实体识别模型对实体边界模糊与语义重叠问题的识别能力不足,利用局部语义区分模块,通过建模当前跨度与邻域跨度的表示差异,引导模型关注细粒度语义差异,从而提升嵌套实体的识别准确性。该方法在GENIA 英文数据集和自建中文嵌套数据集上分别取得了81.27%和82.26%的F1 值,对比基线模型分别提升了0.52%和1.48%的F1值,验证了它对嵌套命名实体识别任务的有效性。

**关键词:** 嵌套命名实体识别; 证据理论; 局部语义区分

## Nested named entity recognition based on evidence theory and local semantic distinction

Bobo Xu<sup>1</sup>, Na Ye<sup>1</sup>, Mingchong Jiang<sup>1\*</sup>  
<sup>1</sup>School of Computer Science, Shenyang Aerospace University  
xubobo@stu.sau.edu.cn, yena\_1@126.com  
jiangming2@stu.sau.edu.cn

## Abstract

Nested named entity recognition (NER) is a fundamental task in natural language processing that aims to identify and extract nested entities and their semantic types using computational techniques. The prevailing approach to nested NER is span-based modeling, which treats the task as a span classification problem and has proven effective in handling hierarchical structures. However, such methods often struggle to distinguish subtle semantic differences between similar entities, and their exhaustive enumeration of candidate spans introduces substantial noise, thereby degrading overall performance. To address these issues, we propose a novel approach that incorporates both uncertainty estimation and local semantic discrimination. Our method quantifies the model's predictive uncertainty and uses it to guide inference, thereby mitigating

the impact of noisy spans. Specifically, we design an uncertainty-guided KNN-assisted decision mechanism that calibrates predictions under high uncertainty by leveraging prior knowledge from similar labeled entities in the training space. Additionally, to address the model's limitations in resolving boundary ambiguity and semantic overlap among nested entities, we introduce a local semantic discrimination module. This module explicitly models the representation differences between the current span and its surrounding spans, enabling the model to capture fine-grained semantic distinctions and thereby improve recognition accuracy. Experiments on the GENIA English dataset and a self-constructed Chinese nested NER dataset demonstrate the effectiveness of our approach, yielding F1-scores of 81.27% and 82.26%, respectively—representing gains of 0.52% and 1.48% over strong baselines.

**Keywords:** nested named entity recognition, evidence theory, local semantic differentiation

## 1 引言

嵌套命名实体识别 (Named Entity Recognition, NER) (邓依依 et al., 2021) 是一种利用计算机辅助技术识别并提取实体及其对应语义类型的任务 (Lample et al., 2016), 这些语义类型包括人名 (PER)、地点 (LOC)、地缘政治实体 (GPE) 等。NER 在推动多个下游任务中发挥着关键作用, 例如关系抽取 (Tang et al., 2022)、事件抽取 (Yang and Mitchell, 2016) 以及情感分析 (Liu et al., 2023)。

针对嵌套命名实体识别任务, 现有研究模型主要可分为基于分层序列的方法与基于跨度分类的方法。前者通过动态堆叠多个序列标注层以识别嵌套实体 (Ju et al., 2018), 虽能在一定程度上捕捉不同层级的实体信息, 但容易引发错误级联问题, 且信息传递具有单向性, 导致内层实体难以有效利用外层实体的上下文信息。后者则将实体识别建模为一个跨度分类任务 (Sohrab and Miwa, 2018), 通过枚举可能重叠的文本跨度来展开嵌套结构, 能够较好地挖掘跨度内部的标记特征。然而, 此类方法普遍基于彼此独立的、碎片化的跨度进行分类, 忽略了跨度间的相互关联, 难以区分相似跨度的语义信息。

尽管基于跨度的方法在嵌套命名实体识别中取得了显著成果, 但由于缺乏对实体边界的显式引导, 这类方法往往难以充分利用跨度内部丰富的语义信息。已有研究表明, 当处理具有高度重叠的嵌套实体时, 基于跨度的模型通常容易产生混淆 (Tan et al., 2021; Zhu and Li, 2022)。

基于跨度的嵌套命名实体识别方法需要枚举文本中所有可能的跨度, 以识别潜在的实体, 但这一过程会生成大量与真实实体跨度重叠的非实体跨度, 导致模型在处理这些噪声跨度时容易产生误判, 从而影响预测的准确性。现有的嵌套命名实体识别研究主要聚焦于提升模型性能, 如识别准确率和 F1 分数, 而对模型可靠性的关注较少。模型可靠性的核心在于预测结果的不确定性估计, 即表征模型预测可能出错的概率。一种常见的构建预测不确定性的方法是基于 Softmax 输出的最大值, 其中该值越小, 不确定性越高。然而, 实验表明, 深度神经网络 (如 Transformer 和 CNN) 产生的概率预测往往不准确, 可能导致不确定性估计过高或过低 (Guo et al., 2017; Pinto et al., 2022), 特别是在高重叠度的非实体跨度干扰下, 进一步加剧模型误判的风险, 从而显著影响嵌套命名实体识别的性能。

为解决上述问题, 本文提出了基于不确定度引导的 KNN 辅助决策和局部语义区分模型 (Uncertainty-Guided KNN-assisted decision-making and local semantic differentiation model, UGKNNLSD), 该方法显式地将嵌套跨度之间的语义差异作为输入特征引入。通过反向传播机制, UGKNNLSD 能够学习合适的内部表示, 从而增强在跨度语义表示空间中区分嵌套实体的能力, 提升边界识别与嵌套命名实体分类的准确性。具体而言, UGKNNLSD 结合了 BERT 与双仿射注意力机制, 构建出一个包含跨度语义表示的矩阵, 随后通过局部语义区分模块对该矩阵进行转换, 以获得不同跨度之间的语义差异表示。同时, 模型在处理高重叠度

\* 通讯作者

©2025 中国计算语言学大会

根据《Creative Commons Attribution 4.0 International License》许可出版

基金项目: 国家自然科学基金项目(U1908216)

的非实体跨度时容易产生误判。UGKNNLSD通过量化不确定度和为低证据跨度分配较低的置信度，有效过滤噪声跨度对模型的影响，提升了模型的性能。

## 2 相关工作

### 2.1 嵌套命名实体识别

目前对于嵌套命名实体识别所研究的方法可以分为基于超图的方法、基于分层的方法、序列标注和基于跨度的方法，目前主流的研究方法是基于跨度的方法。

基于超图的方法采用超图模型（Hypergraph Method）(Lu and Roth, 2015)进行嵌套命名实体识别的研究。该方法通过将嵌套实体结构映射至超图中的子图结构，进而基于此构建相应的分类模型，从而实现对嵌套命名实体的高效识别与精准分类。然而超图模型需要构建复杂的图结构，包含节点（词或跨度）与超边（表示实体关系或嵌套关系），其构造和推理过程计算成本较高，尤其是在长文本或实体密集的场景下，计算复杂度可能呈指数级增长，导致处理效率低下。

基于分层的方法（Hierarchical Method）(Ju et al., 2018)通过将实体划分为多个层级，每一层均表征更高级的实体特异性。在此范式下，Wang 等人(Wang and Lu, 2020)提出了一种基于卷积神经网络的金字塔式序列标注架构，该架构能够自底向上地逐层提取实体特征。分层方法通常采用逐层识别的策略（如先识别外层实体，再识别内层实体），每一层的预测误差会传递到后续层，导致误差累积。特别是在嵌套层级较深或实体边界复杂时，早期层的误判可能显著影响整体性能。

相较而言，序列到序列（Seq2Seq）方法提供了一种更为简洁高效的端到端解决方案。该方法通常基于长短期记忆网络与条件随机场（LSTM-CRF）(Straková et al., 2019)或双向自回归变换器（BART）(Yan et al., 2021a)模型，对文本序列中的每个位置进行标签预测。在此基础上，Zhang 等人(Zhang et al., 2022b)通过引入实体内部与实体之间的去偏数据增强策略，进一步优化了Seq2Seq 方法的性能。然而，当面对高度复杂的嵌套结构时，此类方法可能会因长距离依赖问题而导致级联错误的出现，从而影响模型的整体性能。

为有效应对嵌套命名实体识别任务中的复杂挑战，Sohrab 和Miwa(Sohrab and Miwa, 2018)提出了一种基于跨度（span-based）的创新方法。该方法将嵌套命名实体识别任务重新建模为跨度预测问题，通过预测每个词元可能构成的实体跨度，并对这些跨度进行后续的过滤与合并操作，最终实现嵌套实体的准确识别。

在此基础上，Yu 等(Yu et al., 2020)引入了双仿射注意力机制，以增强起始词与结束词之间的交互作用，并为每个跨度分配相应的得分，从而进一步提升了跨度预测的准确性。在构建基于跨度的对比损失函数方面，Zhang 等(Zhang et al., 2022a)采用拼接操作生成跨度表示，为模型训练提供了有效的优化目标。与此同时，Shen 等(Shen et al., 2023)将命名实体识别任务重新定义为一种边界去噪扩散过程，通过逐步精化噪声跨度，实现了实体的高效生成。

然而，现有的基于跨度的模型在生成跨度表示时，通常依赖于池化（pooling）、拼接（concatenation）或集合（aggregation）等技术。这些方法在处理高度重叠的跨度时，往往会生成语义上高度相似的表示，从而难以有效捕捉个体跨度之间细微的语义差异。

### 2.2 证据深度学习

证据深度学习（Evidence-based Deep Learning, EDL）(Bao et al., 2021)是一种旨在增强深度学习模型对预测结果不确定性建模能力的新兴方法。传统的深度学习模型通常基于softmax层输出类别概率，具有显著的确定性特点，即在输入相同样本时输出固定的预测结果。然而，在实际应用中，由于数据噪声、标签不一致性、模型参数误差以及环境变化等因素的影响，模型预测往往不可避免地带有不确定性。因此，对预测结果进行不确定性量化，对于提高模型的可靠性、安全性及可解释性具有重要意义。

EDL方法以主观逻辑中的Dempster-Shafer证据理论（Evidence Theory）(Shapiro, 1992)为基础，通过引入狄利克雷分布（Dirichlet Distribution）对模型输出的类别分布建模。与传统softmax输出将模型预测值解释为概率分布不同，EDL将神经网络输出解释为对每个类别支持证据的集合。这些证据被用于参数化狄利克雷分布，从而获得一个明确表示预测分布不确定性的先验概率模型。狄利克雷分布中各类别参数的大小不仅反映了对某一类别的支持程度（即“证

据”多少)，也蕴含了整个分布的置信强度，使得EDL模型能够同时输出预测结果与其不确定性估计。

在EDL的训练过程中，通常采用正态分布作为观测数据的似然函数，而狄利克雷分布作为先验进行贝叶斯推断。在优化目标函数中，引入Kullback-Leibler (KL) 散度作为正则项，以惩罚网络输出的预测分布偏离统一分布（即无偏或最大不确定性）的程度，进而鼓励模型在信息不足时保持较高的不确定性表达，从而提升模型在不确定区域的鲁棒性。

与传统的不确定性估计方法，如贝叶斯神经网络 (Bayesian Neural Networks, BNN) 相比，EDL具有显著的计算效率优势。BNN需要对后验分布进行近似推断，常通过变分贝叶斯推断或多次蒙特卡洛采样来实现，计算成本高、实现复杂；而EDL则在单次前向传递中即可完成对预测分布及其不确定性的估计，避免了高昂的推理开销。

### 3 模型和方法

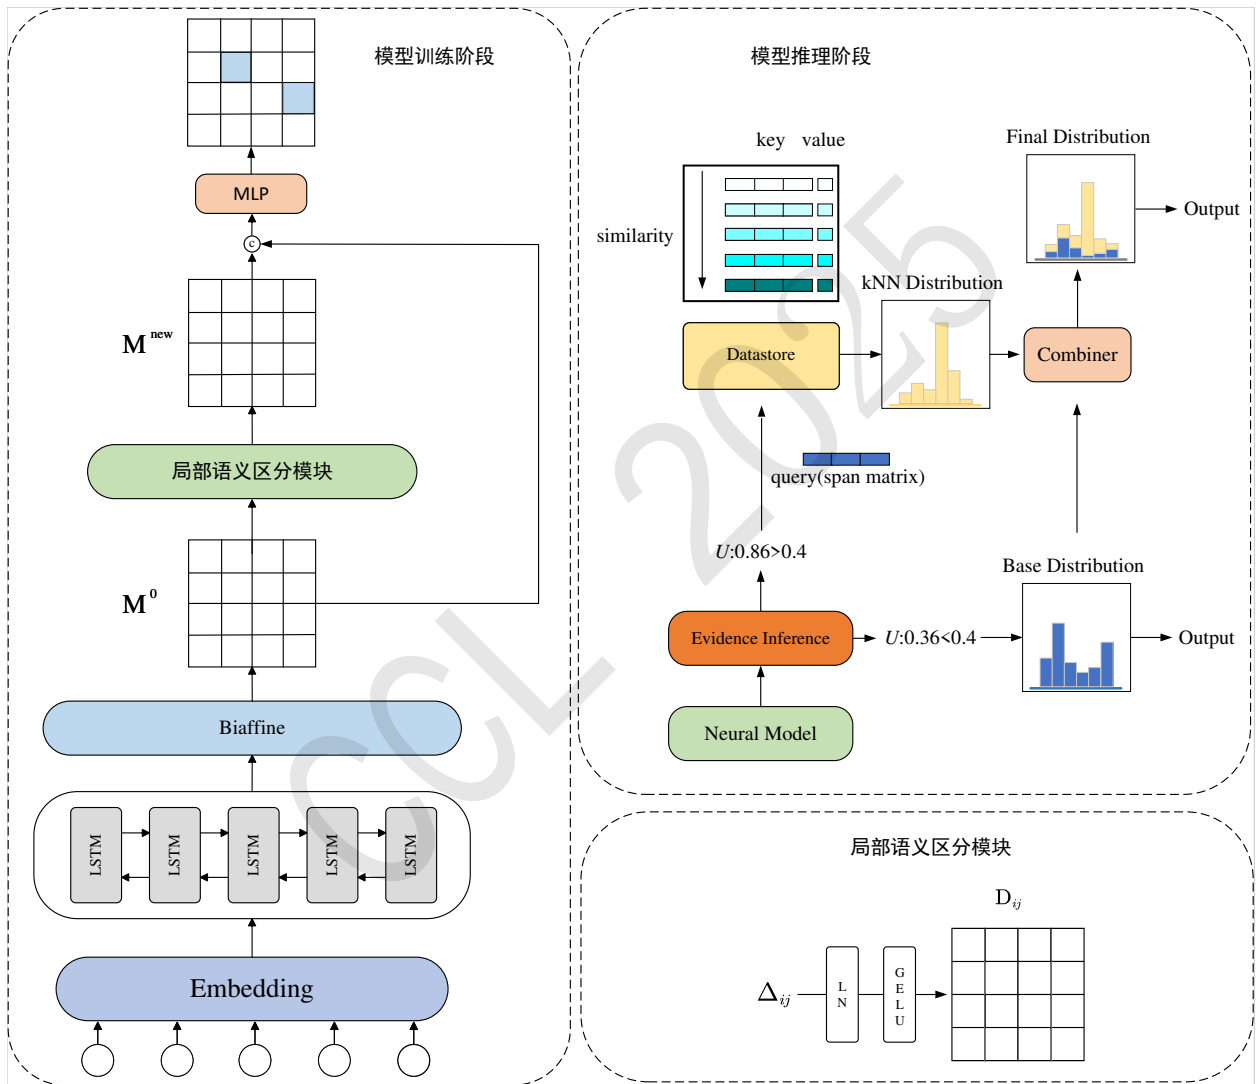


图 1: UGKNLSD模型结构示意图

针对嵌套命名实体识别任务难以区分相似跨度的语义信息和噪声跨度影响模型性能的问题，本文提出一种基于不确定度引导的KNN辅助决策和局部语义区分方法。具体的模型架构如图1所示。

#### 3.1 编码层

给定一个句子  $X = \{x_1, x_2, \dots, x_N\}$ ，将每个单词转换为单词片段，然后将它们输入到预



训练的BERT (Bidirectional-Encoder Representations from Transformers, BERT) (Devlin et al., 2019) 模型中。为了进一步增强上下文建模, 采用双向LSTM (Long Short-Term Memory Network, LSTM) (Hochreiter and Schmidhuber, 1997) 把从前往后和从后往前运行将前后的信息融合在一起, 使模型可以全面地考虑到输入序列中每个时刻的前后上下文信息, 最终生成的词表征如下:

$$H = \{h_1, h_2, \dots, h_N\} \quad (1)$$

其中 $h_i \in R^{1 \times h}$ ,  $h$  表示隐藏层的维度;  $H \in R^{N \times h}$ 。

### 3.2 双仿射层

本文设计了两个前馈神经网络 (FNN) 来映射标记, 并获得一个跨度的起始和结束标记 $h_s, h_e \in R^{l \times h}$  的语义表示向量, 其中 $l$  表示句子长度,  $h$  表示隐藏层维度。随后, 采用双仿射模型将起始和结束标记的表示, 以及跨度的宽度表示 $w_{ij} \in R^{1 \times c}$  进行组合, 以构建跨度表示矩阵 $M^0 \in R^{l \times l \times f}$ , 其中 $f$  对应双仿射特征的数量。

对于每个从第 $i$  个标记到第 $j$  个标记的跨度 $S_{i,j}$ , 其向量 $M_{ij}^0$  的计算方式如下:

$$\begin{aligned} h_s &= \text{GELU}(\mathbf{H}_{enc} \mathbf{W}_s), \\ h_e &= \text{GELU}(\mathbf{H}_{enc} \mathbf{W}_e), \\ \mathbf{M}_{ij}^0 &= (\mathbf{h}_s[i] \oplus \mathbf{h}_e[j] \oplus \mathbf{w}_{ij}) \mathbf{W} + \mathbf{h}_s[i] \mathbf{U} \mathbf{h}_e[j]^T \end{aligned} \quad (2)$$

### 3.3 局部语义区分模块

为了有效捕捉不同跨度之间的语义差异, 增强模型对语义相似但语义功能不同的实体跨度的辨识能力, 本文引入局部语义区分模块。该模块通过邻域建模与语义差分计算, 精细化建模实体与其上下文之间的语义微差, 从而提升模型对细粒度实体边界的区分能力。

具体地, 对于每一个候选实体跨度的表示向量 $\mathbf{M}_{ij}^0$ , 定义了一个固定邻域 $\text{Neighbor}(i, j)$ 。本文选择 $3 \times 3$  窗口 (包含 $i \pm 1, j \pm 1$  的跨度), 以在保证计算效率的同时兼顾上下文覆盖能力。无效跨度 (例如超出句子长度或 $i > j$  的情况) 被排除, 确保邻域只包含合法跨度。

计算当前跨度与其邻域跨度的语义差异:

$$\Delta_{ij}^{\text{raw}} = \mathbf{M}_{ij}^0 - \frac{1}{k} \sum_{(m,n) \in \text{Neighbor}(i,j)} \mathbf{M}_{mn}^0 \quad (3)$$

其中 $k$  是邻域内有效跨度的数量 (通常为4-8, 取决于边界条件)。 $\Delta_{ij}^{\text{raw}}$  表示当前跨度与其邻域平均表示的语义偏差, 作为初步差异估计。

随后引入自适应加权注意力, 基于当前跨度与其邻域的语义相似性计算注意力权重:

$$w_{mn} = \text{softmax} \left( \frac{\mathbf{M}_{ij}^0 \cdot \mathbf{M}_{mn}^0}{\sqrt{f}} \right), (m, n) \in \text{Neighbor}(i, j) \quad (4)$$

其中 $\cdot$  表示点积,  $\sqrt{f}$  用于缩放以避免数值过大。 $w_{mn} \in [0, 1]$  表示邻域跨度 $(m, n)$  的相对重要性。使用 $\Delta_{ij}^{\text{raw}}$  作为基础, 结合注意力权重进一步细化差异:

$$\Delta_{ij} = \Delta_{ij}^{\text{raw}} + \sum_{(m,n) \in \text{Neighbor}(i,j)} w_{mn} (\mathbf{M}_{ij}^0 - \mathbf{M}_{mn}^0) \quad (5)$$

随后, 对优化后的差异应用激活和归一化:

$$\mathbf{D}_{ij} = \text{LN}(\text{GELU}(\Delta_{ij})) \quad (6)$$

最后, 将差异特征矩阵 $\mathbf{D}_{ij}$  与原始表示矩阵 $\mathbf{M}_{ij}$  结合, 生成新的上下文增强表示矩阵 $\mathbf{M}^{\text{new}} \in R^{f \times i \times j}$ 。

$$\mathbf{M}_{ij}^{\text{new}} = \text{Linear}(\mathbf{M}_{ij}^0 \oplus \mathbf{D}_{ij}) \quad (7)$$

### 3.4 解码器

为了保留跨度的完整语义信息，本文将 $\mathbf{M}^0$ 作为残差添加到 $\mathbf{M}^{new}$ 中。然后，复合矩阵经过线性解码得到预测的概率：

$$p = \sigma(W_p(M^0 \oplus M^{new}) + B_p) \quad (8)$$

其中， $p \in R^{l \times l \times t}$ ,  $W_p \in R^{d \times t}$ ,  $B_p \in R^t$ 。  $W_p$  和  $B_p$  是可训练参数， $\sigma$  表示Sigmoid 激活函数。

### 3.5 不确定度

为了评估模型对NER任务中预测的自信程度，受证据回归启发(Amini et al., 2020)，本文选择RELU等非线性激活函数来代替传统的Softmax层。激活函数的输出值将被视为对应样本提供的证据量，为其分类提供支持。随后，本文利用这些证据量参数化狄利克雷分布，以模型形式捕捉各类别的概率分布。Dirichlet分布代表了每个候选概率分配的密度，它模拟了不确定性。对于N个候选的实体类型推理过程，其Dirichlet分布定义为：

$$D(\mathbf{p}|\alpha) = \frac{1}{B(\alpha)} \prod_{i=1}^N p_i^{\alpha_i-1} \quad \text{for } \mathbf{p} \in S_N \quad (9)$$

其中 $\alpha_i$  代表了证据支持量的量化， $S_N$  是N类候选的单元锥形， $B(\alpha)$  为N类候选的多项式beta 方程。

在NER 任务中，可以采用主观逻辑框架量化模型对每个实体被分类为某一类预定义类别时的信念强度。每个实体针对某一类别标签 $i$  ( $i = 1, \dots, N$ , 其中N 表示类别的总数)，都由一个信念质量 $b_i$  表示，其反映了模型对预测为该类别的信心水平。同时，不确定性质量 $u$  提供了模型对最终预测的不确定性的量化，即当存在歧义或信息不足导致难以做出准确分类时，模型的不确定性水平 $u$  的值越高，表示模型对该类别的分类越不确定。信念质量 $b_i$  和不确定性质量 $u$  的设计满足以下条件：

$$u + \sum_{i=1}^N b_i = 1 \quad (10)$$

对任意 $n = 1, \dots, N$ ，都有 $u \geq 0$  且 $b_n \geq 0$ 。每个实体的信念质量基于其相应的证据量 $e_i$  进行量化，并假设其为非负值。计算单个信念质量 $b_i$  和整体不确定性 $u$  如下：

$$b_i = \frac{e_i}{S}, \quad u = \frac{N}{S} \quad (11)$$

其中 $S$  表示整体的证据，即狄利克雷分布的强度。在这种情形下，不确定性 $u$  与整体证据 $S$  成反比。若缺乏证据，不确定度 $u$  也会偏大。

### 3.6 损失函数

本文定义的损失函数 $\mathcal{L}$  为：

$$\mathcal{L} = \mathcal{L}_{CLS} + \mathcal{L}_{KL} \quad (12)$$

其中， $\mathcal{L}_{CLS}$  表示交叉熵损失，用于评估模型预测与真实标签序列的一致性； $\mathcal{L}_{KL}$  表示KL散度，量化模型预测分布与目标分布之间的差异。

本文构建了一种综合损失函数，旨在综合考虑类别预测中的贝叶斯风险。该损失函数通过交叉熵损失度量预测精度，并结合狄利克雷分布计算具体损失值，从而优化模型的预测分布。损失函数的定义如下：

$$\mathcal{L}_{CLS} = \int \left[ \sum_{j=1}^K -y_{ij} \log(p_{ij}) \right] \frac{1}{B(\alpha_i)} \prod_{j=1}^K p_{ij}^{\alpha_{ij}-1} dp_i = \sum_{j=1}^K y_{ij} (\psi(S_i) - \psi(\alpha_{ij})) \quad (13)$$

其中 $y_{ij}$  是真实标签的指示函数； $p_{ij}$  是模型预测样本 $i$  属于 $j$  类别的概率； $B(\cdot)$  表示Dirichlet 分布的标准化常数； $K$  表示类别的总数； $\alpha_{ij}$  是Dirichlet 分布的参数，反映了对第 $i$  个样本属于第 $j$  类的信念强度。 $\Psi(\cdot)$  为digamma 方程。

进一步地，为了对预测分布进行正则化并惩罚那些错误的不确定性预测，本文引入了基于KL 散度的损失项 $\mathcal{L}_{KL}$ ：

$$\mathcal{L}_{KL} = \log \left( \frac{\Gamma \left( \sum_{k=1}^K \tilde{\alpha}_{ik} \right)}{\Gamma(K) \prod_{k=1}^K \Gamma(\tilde{\alpha}_{ik})} \right) + \sum_{k=1}^K (\tilde{\alpha}_{ik} - 1) \left[ \psi(\tilde{\alpha}_{ik}) - \psi \left( \sum_{j=1}^K \tilde{\alpha}_{ij} \right) \right] \quad (14)$$

这里的 $\Gamma(\cdot)$  为gamma 函数； $\psi(\cdot)$  为digamma 函数； $\tilde{\alpha}$  是调整后的狄利克雷分布参数，其反映了模型对不同类别的预测信心。

### 3.7 不确定度引导的KNN辅助决策

在推理阶段，本文提出一种基于不确定度引导的K 近邻 (K-Nearest Neighbors, KNN) (Cover and Hart, 1967)辅助决策机制。当模型对某一候选实体标签的预测不确定度 $u$  超过预设阈值 $\tau$ ，本文认为模型在该实例上缺乏充分置信，存在误判的风险。为此，本文设计并利用以下方法对推理进行修正。

当某一实体的预测不确定度满足 $u > \tau$ ，则利用K 近邻 (K-Nearest Neighbors, KNN) 辅助预测。具体而言，本文在训练阶段缓存所有标注实体的表示向量，并构建特征空间中的实体库。在推理阶段，对当前不确定实体的表示向量 $m_{ij}$  (模型训练阶段得到) 进行KNN 搜索，检索与其最相似的 $k$  个已标注实体样本，依据其标签分布进行投票或加权平均，以产生一个修正后的预测分布 $p_{knn}$ 。

最终的预测结果通过原模型输出分布 $p_{model}$  与KNN 预测分布 $p_{knn}$  的加权融合实现：

$$p_{final} = (1 - \lambda(u)) \cdot p_{model} + \lambda(u) \cdot p_{knn} \quad (15)$$

其中融合权重函数 $\lambda(u)$  随不确定度动态变化。为避免在阈值附近产生较大的变化，本文采用如下线性过渡机制：

$$\lambda(u) = \begin{cases} \frac{u - \tau_1}{\tau_2 - \tau_1} & \text{if } \tau_1 < u < \tau_2 \\ 1 & \text{if } u \geq \tau_2 \end{cases} \quad (16)$$

其中 $\tau_1 = 0.4$ ,  $\tau_2 = 0.8$ ，确保KNN 在高不确定度区域逐步发挥作用，而不会干扰模型在置信度较高区域的独立判别能力。

## 4 实验与分析

### 4.1 实验设置

为了验证本文提出的方法的有效性，本文在两个数据集：GENIA 英文数据集(Kim et al., 2003)和自建数据集上进行实验。

GENIA 数据集包含32 个嵌套的生物医学实体类别，本文遵循文献(Yan et al., 2021b)专注于五种实体类型：DNA、RNA、蛋白质、细胞谱系和细胞类型，并将训练集、验证集和测试集分割为8:1:1。该数据集专注于生物医学领域，包含复杂的嵌套实体结构，适合评估本文方法在特定领域的泛化性能。

自建嵌套数据集数据来源于中文信息学报的标题和摘要，选取了2022-2017 年标题和摘要进行标注。该数据集对计算语言学领域的术语进行了定义以及人工标注，采用元组的标注法，标注结构为(s, e, t)元组，分别表示术语左边界、右边界及术语类型。该数据集术语分为混合型嵌套术语、单一型嵌套术语和非嵌套术语三种类型。为防止术语错标漏标，自建嵌套数据集采用二次人工判定的方法进行数据校验。校验后文本总数为3000，术语总量14025 个，其中非嵌套术语7932 个，嵌套术语6093 个。所引用的领域词典中共有468 个词汇，出现在自建数据集中的有142 个，与所标注术语直接匹配的有88 个，通过匹配可完全识别的术语有1686 个，通过词汇拼接可完全匹配1730个术语。将数据集按7:2:1 随机切分为训练集、验证集和测试集。

本文的模型由Pytorch框架和NVIDIA TITAN RTX GPU 实现。本文模型的核心构成如下：英文文本表示由预训练的语言模型RoBERTa-base 初始化，中文文本表示由预训练的语言模型BERT-base-Chinese初始化，并在训练阶段进行微调。本文设置句子输入的最大长度为128，隐藏层维度为768。检索的相似跨度表示矩阵个数为7个。在训练过程中，本文设置在每个epoch后评估模型在验证集上的性能表现，并选择具有最佳F1值得分的模型，最后在测试集上评估其性能。

## 4.2 实验结果

本文的评估采用三个关键指标：准确率（Precision）、召回率（Recall）和F1分数（F1-score），以衡量模型的性能。本文采用严格的评估标准，要求在实体边界和类别两方面完全匹配，方视为识别正确。为验证实验结果的一致性与可靠性，本文进行了五次独立试验，每次使用不同的随机种子初始化，并对所得的F1分数进行统计分析。具体而言，本文在5%的显著性水平下应用T检验，以判断实验结果之间差异的统计显著性。

为了证明本文方法的有效性，本文分别在自建数据集和GENIA数据集上将其与以下模型进行比较：Baffine(Yu et al., 2020)、Locate-and-Label(Shen et al., 2021)、Seq2Seq(Tan et al., 2021)、Span-Graph(Wan et al., 2022)、De-bias(Zhang et al., 2022c)、BS(Zhu and Li, 2022)、DiffusionNER(Shen et al., 2023)、GPT-NER(Wang et al., 2023)。

**Baffine:** 该论文引入了双仿射注意力机制，以增强起始词与结束词之间的交互作用，并为每个跨度分配相应的得分，从而进一步提升了跨度预测的准确性。

**Locate-and-Label:** 这篇论文提出了一种两阶段识别框架，第一阶段：识别所有“最外层”的实体；第二阶段：在第一阶段识别出的实体基础上，进一步识别被嵌套在其中的“内层实体”。通过逐层抽取的方式，有效缓解了嵌套结构带来的重叠和边界模糊问题。

**Seq2Seq:** 该论文提出了一种创新的嵌套命名实体识别（Nested NER）方法，将该任务建模为“序列到集合”的问题，以解决传统方法在处理嵌套实体时面临的挑战。

**Span-Graph:** 作者引入了两种基于n-gram 相似度构建的图结构，通过将这些图结构集成到模型中，增强了跨度表示的语义表达能力，提高了模型对嵌套实体的识别效果。

**De-bias:** 作者从因果推理的角度出发，提出了两种去偏数据增强方法，以消除前文混淆因子和实体顺序混淆因子的影响。

**BS:** 为缓解模型对预测结果的置信度过高，导致泛化能力下降的问题，作者受标签平滑（Label Smoothing）技术的启发，提出了边界平滑方法。该方法通过将标注实体的概率分布扩散到其周围的非实体跨度上，降低模型的过度自信。

**DiffusionNER:** 该方法在训练阶段通过固定的前向扩散过程，逐步向真实实体边界添加高斯噪声，生成“噪声跨度”；然后，模型学习一个反向扩散过程，以从这些噪声跨度中恢复出原始的实体边界，在推理阶段从标准高斯分布中随机采样噪声跨度，利用训练好的反向扩散过程进行去噪，最终生成实体边界。

**GPT-NER:** 该论文将序列标注任务转化为大语言模型的生成任务，并引入自我验证机制以提升实体识别性能。

通过对比分析可以发现，本文提出的方法在两个数据集上均达到了最优的F1值，这表明本文的模型可以在准确率和召回率间取得平衡，充分证明了其在嵌套命名实体识别任务中的有效性。

表1全面展示了本文的模型与各基线模型在自建数据集和GENIA数据集上的嵌套命名实体识别性能。在自建数据集和GENIA数据集上，本文的模型均稳定优于基线模型。本文的模型在自建数据集上表现出1.48%的F1提升，在GENIA数据集上表现出0.57%的F1提升。以上结果凸显了本文的模型在应对嵌套命名实体识别复杂性方面的优越性能。

鉴于当前大规模语言模型在自然语言处理任务中的广泛应用，本文在GENIA数据集上引入了与GPT-NER 的对比实验。GPT-NER 将序列标注任务转化为大语言模型的生成任务，并引入自我验证机制以提升实体识别性能。实验结果表明，本文所提出的模型在性能上显著优于GPT-NER。尽管GPT-NER 借助了生成式语言模型强大的文本建构能力，但其主要依赖语言模型的通用生成能力，缺乏对任务特定特征的精细建模。相比之下，本文方法在语义区分与表示方面更具针对性，进一步验证了其在嵌套命名实体识别任务中的有效性与优势。



Models	自建数据集			GENIA		
	P(%)	R(%)	F1(%)	P(%)	R(%)	F1(%)
Biaffine	78.24	77.63	77.93	81.80	79.30	80.50
Locate-and-Label	78.96	72.65	75.67	80.19	80.89	80.54
Seq2Seq	76.16	75.88	76.02	78.57	79.30	78.93
Span-Graph	73.11	74.37	73.73	77.92	80.74	79.30
De-bias	75.82	75.10	75.46	81.04	77.21	79.08
BS	77.45	76.93	77.19	<b>82.53</b>	78.69	80.56
DiffusionNER	80.31	81.25	80.78	81.85	79.59	80.70
GPT-NER	-	-	-	61.89	66.95	64.42
Ours	<b>82.49</b>	<b>82.03</b>	<b>82.26</b>	81.59	<b>80.96</b>	<b>81.27</b>

表 1: 对比不同基线的实验结果

4.3 消融实验

为了探究本文提出的方法的有效性，本文对UGKNNLSD中各个部分进行了消融实验，实验结果如表2所示，其中“w/o”表示去除单个组件或多个组件。本文系统地移除了UGKNNLSD中的关键组件，包括语义区分模块和KNN辅助决策模块。

模型设置	自建数据集			GENIA		
	P(%)	R(%)	F1(%)	P(%)	R(%)	F1(%)
w/o-语义区分	79.43	78.32	78.87	80.75	80.41	80.58
w/o-KNN辅助	79.08	77.41	78.24	80.81	80.52	80.66
w/o-语义区分, KNN辅助	76.85	75.31	76.07	80.27	79.93	80.10
默认	<b>82.49</b>	<b>82.03</b>	<b>82.26</b>	<b>81.59</b>	<b>80.96</b>	<b>81.27</b>

表 2: 消融实验结果

当单独移除语义区分模块时，明显观察到F1值的下降，语义区分模块可显式建模嵌套实体中重叠区域间的偏差，提高辨别能力。若移除该模块，模型更容易出现实体合并或拆分错误。当单独移除KNN辅助模块时，F1值也下降了很多，表明原模块可在模型对某些边界或标签不确定时，利用“先验知识”（即训练样本空间中的相似实体）来做决策修正。去除后，模型只能依赖自身当前参数和预测结果，易在边界模糊或类间语义接近的实体上发生误判，证明了KNN辅助模块的有效性。

实验结果表明，语义区分模块与KNN辅助推理模块在整体识别性能中均起到关键作用。前者增强了模型对局部语义差异的建模能力，而后者显著提升了模型在高不确定度样本上的预测鲁棒性。两者共同协作，有效缓解了嵌套实体识别中因边界模糊与语义重叠带来的误识别问题。消融这两部分后模型F1 值的下降，进一步验证了其在提升实体识别精度方面的重要性。

4.4 取值分析

不确定度阈值 $\tau$ 的取值和k值的选取也会影响UGKNNLSD的性能，本文还对不同的取值在GENIA数据集上进行了实验，实验结果如表3所示。

针对 $\tau$ 和k的不同取值进行分析，可以看出 $\tau$ 固定为0.4时，当k值不断增加，F1值反而不断降低，当k为7时效果最佳。当k固定为7时，随着 $\tau$ 值的不断增加，F1值不断降低当 $\tau$ 为0.4时效果最佳。

4.5 边界识别准确性分析

为了验证本文提出的模型对于边界识别准确性的提升，本文进行了实验对比，包括了相关研究中的经典模型。具体而言，我们在自建数据集上，将本文提出的模型

参数设置	P (%)	R (%)	F (%)
$\tau=0.4,k=5$	80.78	80.19	80.48
$\tau=0.4,k=7$	<b>81.59</b>	<b>80.96</b>	<b>81.27</b>
$\tau=0.4,k=9$	80.11	79.47	79.79
$\tau=0.4,k=11$	78.94	79.05	78.99
$\tau=0.2,k=7$	79.06	78.45	78.75
$\tau=0.3,k=7$	80.14	79.42	79.78
$\tau=0.4,k=7$	<b>81.59</b>	<b>80.96</b>	<b>81.27</b>
$\tau=0.5,k=7$	78.21	77.63	77.91

表 3: 不同取值的实验结果

与CNINNER和DiffusionNER的性能进行了比较，结果见表4。所有模型均使用BERT-base-Chinese作为语言模型进行了预训练。结果显示，UGKNNLSD在自建数据集上对所有长度的实体识别方面达到了最先进的水平。值得注意的是，在自建数据集中，UGKNNLSD在识别长度为5到8和8到12的实体时，分别实现了+9.26%和+7.41%的显著提升。这些改进突显了UGKNNLSD在识别重叠和扩展跨度中的细微语义差异方面的能力，从而增强了其识别复杂实体边界的性能。

Datasets	Len	%	CNINNER	DiffusionNER	Ours	Improvement (%)
自建数据集	(0,3]	33.87	88.32	85.46	89.66	+1.34
	(3,5]	34.94	84.73	51.45	85.62	+0.89
	(5,8]	19.49	71.83	38.46	81.09	+9.26
	(8,12]	5.70	72.94	33.48	80.35	+7.41
	(12,+ $\infty$ )	5.99	62.43	49.76	73.57	+11.14

表 4: 边界识别准确性实验结果

4.6 模型训练与推理效率分析

为了评估本文方法在实际应用中的时间与资源开销，我们对模型在训练与推理阶段的效率进行了分析，并与不引入KNN推理的基线模型进行了对比。实验采用GENIA 数据集，在相同的硬件环境下进行，所有模型均在单张NVIDIA TITAN RTX GPU 上运行。我们选取了以下三种模型进行比较：

- Baseline: 不包含KNN推理模块的原始Biaffine 模型；
- PIQN(Shen et al., 2022): 基于机器阅读理解任务，不同于以往的阅读理解，其将实例查询作为可学习的提示，以并行的方式识别序列中不同位置不同类型的实体。
- Ours: 本文提出的引入KNN推理与局部语义区分的完整模型。

模型类型	训练总耗时(s)	推理平均耗时(s/sample)	推理显存占用(MB)
Baseline	7020	1.1	870
PIQN	11520	4.6	1950
Ours (KNN+FAISS)	8640	2.4	1140

表 5: 模型训练与推理效率对比

在训练阶段，三种模型采用相同的超参数与优化策略，仅在推理阶段引入KNN模块。表5展示了在训练5 epoch 与推理整个测试集所需的总时间与平均每条样本推理耗时。我们还记录了推理过程中的峰值显存使用量，用于反映方法在大规模部署下的可行性。

可以看出，本文提出的方法在训练阶段的时间开销与基线模型基本持平，这主要归因于引入的邻域建模损失项所带来的额外计算。推理阶段，由于需要为每个候选实体执行KNN 检索，

推理时间有所增加，平均每条样本耗时提升约1.3 s。PIQN由于其模型结构的复杂性，训练开销与推理开销都要远远的超出本文的模型。

## 5 结论

为解决嵌套命名实体识别中的噪声跨度对模型性能产生影响和相似语义的实体与非实体易混淆的问题，本文提出了一种基于不确定度引导的KNN辅助决策和局部语义区分模型（UGKNNLSD）。对于高不确定度的推理利用KNN进行辅助决策，过滤噪声跨度的影响。同时，针对相似语义的实体与非实体易混淆的问题，利用语义区分模块生成新的基于该跨度相邻跨度的增强表示矩阵，使模型能够有效捕捉不同跨度之间的语义差异，增强模型对语义相似但语义功能不同的实体跨度的辨识能力。实验结果表明，本文提出的方法与当前主流的实体识别模型相比取得了较好的效果。

## 参考文献

- Alexander Amini, Wilko Schwarting, Ava Soleimany, and Daniela Rus. 2020. Deep evidential regression. *Advances in neural information processing systems*, 33:14927–14937.
- Wentao Bao, Qi Yu, and Yu Kong. 2021. Evidential deep learning for open set action recognition. In *Proceedings of the IEEE/CVF international conference on computer vision*, pages 13349–13358.
- Thomas Cover and Peter Hart. 1967. Nearest neighbor pattern classification. *IEEE transactions on information theory*, 13(1):21–27.
- Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. 2019. Bert: Pre-training of deep bidirectional transformers for language understanding. In *Proceedings of the 2019 conference of the North American chapter of the association for computational linguistics: human language technologies, volume 1 (long and short papers)*, pages 4171–4186.
- Chuan Guo, Geoff Pleiss, Yu Sun, and Kilian Q Weinberger. 2017. On calibration of modern neural networks. In *International conference on machine learning*, pages 1321–1330. PMLR.
- Sepp Hochreiter and Jürgen Schmidhuber. 1997. Long short-term memory. *Neural computation*, 9(8):1735–1780.
- Meizhi Ju, Makoto Miwa, and Sophia Ananiadou. 2018. A neural layered model for nested named entity recognition. In *Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long Papers)*, pages 1446–1459.
- J-D Kim, Tomoko Ohta, Yuka Tateisi, and Jun'ichi Tsujii. 2003. Genia corpus—a semantically annotated corpus for bio-textmining. *Bioinformatics*, 19(suppl\_1):i180–i182.
- Guillaume Lample, Miguel Ballesteros, Sandeep Subramanian, Kazuya Kawakami, and Chris Dyer. 2016. Neural architectures for named entity recognition. *arXiv preprint arXiv:1603.01360*.
- Xueyi Liu, Rui Hou, Yanglei Gan, Da Luo, Changlin Li, Xiaojun Shi, and Qiao Liu. 2023. Aspect-oriented opinion alignment network for aspect-based sentiment classification. In *ECAI 2023*, pages 1552–1559. IOS Press.
- Wei Lu and Dan Roth. 2015. Joint mention extraction and classification with mention hypergraphs. In *Proceedings of the 2015 conference on empirical methods in natural language processing*, pages 857–867.
- Francesco Pinto, Philip HS Torr, and Puneet K. Dokania. 2022. An impartial take to the cnn vs transformer robustness contest. In *European conference on computer vision*, pages 466–480. Springer.
- Stuart C Shapiro. 1992. Encyclopedia of artificial intelligence second edition. *New Jersey: A Wiley Interscience Publication*, page 25.
- Yongliang Shen, Xinyin Ma, Zeqi Tan, Shuai Zhang, Wen Wang, and Weiming Lu. 2021. Locate and label: A two-stage identifier for nested named entity recognition. *arXiv preprint arXiv:2105.06804*.

- Yongliang Shen, Xiaobin Wang, Zeqi Tan, Guangwei Xu, Pengjun Xie, Fei Huang, Weiming Lu, and Yueting Zhuang. 2022. Parallel instance query network for named entity recognition. In Smaranda Muresan, Preslav Nakov, and Aline Villavicencio, editors, *Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pages 947–961, Dublin, Ireland, May. Association for Computational Linguistics.
- Yongliang Shen, Kaitao Song, Xu Tan, Dongsheng Li, Weiming Lu, and Yueting Zhuang. 2023. Diffusionner: Boundary diffusion for named entity recognition. *arXiv preprint arXiv:2305.13298*.
- Mohammad Golam Sohrab and Makoto Miwa. 2018. Deep exhaustive model for nested named entity recognition. In *Proceedings of the 2018 conference on empirical methods in natural language processing*, pages 2843–2849.
- Jana Straková, Milan Straka, and Jan Hajič. 2019. Neural architectures for nested ner through linearization. *arXiv preprint arXiv:1908.06926*.
- Zeqi Tan, Yongliang Shen, Shuai Zhang, Weiming Lu, and Yueting Zhuang. 2021. A sequence-to-set network for nested named entity recognition. *arXiv preprint arXiv:2105.08901*.
- Wei Tang, Benfeng Xu, Yuyue Zhao, Zhendong Mao, Yifeng Liu, Yong Liao, and Haiyong Xie. 2022. Unirel: Unified representation and interaction for joint relational triple extraction. *arXiv preprint arXiv:2211.09039*.
- Juncheng Wan, Dongyu Ru, Weinan Zhang, and Yong Yu. 2022. Nested named entity recognition with span-level graphs. In *Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pages 892–903.
- Jue Wang and Wei Lu. 2020. Two are better than one: Joint entity and relation extraction with table-sequence encoders. *arXiv preprint arXiv:2010.03851*.
- Shuhe Wang, Xiaofei Sun, Xiaoya Li, Rongbin Ouyang, Fei Wu, Tianwei Zhang, Jiwei Li, and Guoyin Wang. 2023. Gpt-ner: Named entity recognition via large language models. *arXiv preprint arXiv:2304.10428*.
- Hang Yan, Tao Gui, Junqi Dai, Qipeng Guo, Zheng Zhang, and Xipeng Qiu. 2021a. A unified generative framework for various ner subtasks. *arXiv preprint arXiv:2106.01223*.
- Hang Yan, Tao Gui, Junqi Dai, Qipeng Guo, Zheng Zhang, and Xipeng Qiu. 2021b. A unified generative framework for various ner subtasks. *arXiv preprint arXiv:2106.01223*.
- Bishan Yang and Tom Mitchell. 2016. Joint extraction of events and entities within a document context. *arXiv preprint arXiv:1609.03632*.
- Juntao Yu, Bernd Bohnet, and Massimo Poesio. 2020. Named entity recognition as dependency parsing. *arXiv preprint arXiv:2005.07150*.
- Sheng Zhang, Hao Cheng, Jianfeng Gao, and Hoifung Poon. 2022a. Optimizing bi-encoder for named entity recognition via contrastive learning. *arXiv preprint arXiv:2208.14565*.
- Shuai Zhang, Yongliang Shen, Zeqi Tan, Yiquan Wu, and Weiming Lu. 2022b. De-bias for generative extraction in unified ner task. In *Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pages 808–818.
- Shuai Zhang, Yongliang Shen, Zeqi Tan, Yiquan Wu, and Weiming Lu. 2022c. De-bias for generative extraction in unified ner task. In *Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pages 808–818.
- Enwei Zhu and Jinpeng Li. 2022. Boundary smoothing for named entity recognition. *arXiv preprint arXiv:2204.12031*.
- 邓依依, 鄢昌兴, 魏永丰, 万仲保, and 黄兆华. 2021. 基于深度学习的命名实体识别综述. 中文信息学报, 35(9):30–45.