

# 基于 ERNIE-BMBD-CRF 模型的中文课程问句 命名实体识别方法研究

秦慧伶<sup>1</sup>, 邢雪枫<sup>2</sup>, 张黔川<sup>1</sup>, 陈嘉豪<sup>1</sup>, 陈雅茜<sup>1</sup>

(1. 西南民族大学计算机与人工智能学院, 四川 成都 610041; 2. 西南民族大学电子信息学院, 四川 成都, 610041)

**摘要:**随着智慧教育的快速普及,如何将课程知识点以更直观的形式进行展示,帮助学生更加高效地学习,已成为教育信息化领域一项重要的研究课题。传统中文命名实体识别方法因忽略文字上下文联系而不易推出被掩盖的文字,因此提出一种基于 ERNIE-BMBD-CRF(EBC)模型的课程问句命名实体识别方法,以有效地从课程问句中识别出知识点实体。首先利用 ERNIE 预训练语言模型对文本词向量进行表征,然后构建 BMBD 层,通过 BiLSTM 模型进行上下文语义特征提取,将边界扩散机制引入到多头注意力机制 MHA 中以增强实体边界信息的捕捉。最后在 CRF 模型中进行序列标签解码,从而完成命名实体识别。实验结果表明:该模型在 CLUENER2020、MSRA 两个公开数据集和自建课程语料数据集上的 F1 值分别为 87.45%、98.48%、81.49%,均优于其他对比模型。

**关键词:**教育信息化;命名实体识别;ERNIE 预训练语言模型;边界扩散

中图分类号:TP391.1

文献标志码:A

文章编号:2095-4271(2025)01-0085-07

## Research on Chinese course question named entity recognition method based on ERNIE-BMBD-CRF model

QIN Huiling<sup>1</sup>, XING Xuefeng<sup>2</sup>, ZHANG Qianchuan<sup>1</sup>, CHEN Jiahao<sup>1</sup>, CHEN Yaxi<sup>1</sup>

(1. School of Computer and Artificial Intelligence, Southwest Minzu University, Chengdu 610041, China;

2. School of Electronic and Information, Southwest Minzu University, Chengdu 610041, China)

**Abstract:** With the rapid popularization of smart education, how to present course knowledge points in a more intuitive form to help students learn more efficiently has become an important research topic in the field of educational informatization. Traditional Chinese named entity recognition methods are difficult to extract obscured text due to ignoring contextual connections. Therefore, a course question named entity recognition method based on ERNIE-BMBD-CRF (EBC) model was proposed to effectively identify knowledge point entities from course questions. Firstly, the ERNIE pre-trained language model was used to represent the text word vectors, and then the BMBD layer was constructed. The BiLSTM model was used to extract contextual semantic features, and the boundary diffusion mechanism was introduced into the multi head attention mechanism MHA to enhance the capture of entity boundary information. Finally, sequence label decoding was performed in the CRF model to complete named entity recognition. The experimental results showed that the F1 values of this model on two public datasets, CLUENER2020 and MSRA, as well as a self built course corpus dataset, were 87.45%, 98.48%, and 81.49%, respectively, which were superior to other comparative models.

**Keywords:** educational informatization; named entity recognition; ERNIE pre-trained language model; boundary diffusion

收稿日期:2024-09-16

通信作者:陈雅茜(1981-),女,副教授,博士,研究方向:人机交互、信息可视化、深度学习。E-mail:yaxichen@swun.cn

基金项目:西南民族大学中央高校优秀学生培养工程项目(2023NYXXS041);西南民族大学横向项目(横 20240096)

目前,中国正步入一个全面的人工智能时代,智慧教育迅速普及.随着在线教育平台的蓬勃发展和课程内容的日益丰富,如何高效、准确地从大量课程问句中提取出关键知识点信息,成为了教育信息化领域积极探索的重要课题.

命名实体识别(NER)指的是在用户提出的自然语言问句中识别出与问句相关的实体<sup>[1]</sup>,进而可以实现信息抽取、分类、问答等高级自然语言处理任务.早期的NER主要依赖于规则和词典,专家需手工制定一系列的规则和模式,用于实体识别,但规则制定耗时、通用性差.随着机器学习的发展,NER主要采用隐马尔可夫模型( Hidden Markov Model, HMM)<sup>[2]</sup>、条件随机场( Conditional Random Field, CRF)<sup>[3]</sup>、最大熵( Maximum Entropy, ME)<sup>[4]</sup>、支持向量机( Support Vector Machine, SVM)<sup>[5]</sup>等算法,对数据特征进行自动学习,泛化能力有所提高,但受语料库质量影响较大.近年来,深度学习如卷积神经网络( Convolutional Neural Network, CNN)<sup>[6]</sup>、循环神经网络( Recurrent Neural Network, RNN)<sup>[7]</sup>、RNN的改进模型长短期记忆网络( Long Short-Term Memory, LSTM)<sup>[8]</sup>以及双向长短期记忆网络( Bidirectional Long Short-Term Memory, BiLSTM)<sup>[9]</sup>在NER任务中取得了显著成效,可自动学习复杂的语言模式,广泛应用于医疗、电商、农业等领域.

为了更有效地捕捉并表征词汇的丰富语义特征, Devlin 等人<sup>[10]</sup>提出了预训练语言模型 BERT,将其引入命名实体识别任务中.但是 BERT 在处理中文时是基于单个字进行编码的,这种方式忽略了文字之间的上下文联系,导致一个词被分割开来,难以推断出被掩盖的文字.针对这一不足, Sun 等人<sup>[11]</sup>提出了基于知识增强的 ERNIE 模型,该模型能够有效地捕捉文字之间的关系,其掩码策略考虑了文字之间的联系,通过以词为单位进行掩码,使模型更容易推断出被遮掩的文字,从而在字词、语句和语义方面学习到更深层次的语言知识.边界扩散机制( Boundary Diffusion, BD)是一种用于命名实体识别任务的创新方法,可以增强实体边界信息捕捉.本文以 ERNIE 预训练模型为基础,将边界扩散引入到多头注意力机制( Multi-Head Attention, MHA)中,提出一种基于 ERNIE-BMBD-CRF 改进模型的中文课程问句命名实体识别

方法,通过融合边界信息增强模型对复杂边界的捕捉能力.

## 1 相关工作

传统的 LSTM-CRF 结构是 NER 领域的一种经典架构, LSTM 模型用于捕捉序列中的特征信息, CRF 则用于处理序列预测问题,能够考虑标签之间的相互关系,生成概率最高的标签序列. Huang 等人<sup>[12]</sup>首次提出 BiLSTM-CRF 模型,通过 BiLSTM 网络对上下文特征进行建模,并结合 CRF 层来捕捉并优化句子级别的标签序列,在相关数据集上取得了良好的表现. Zhang 等人<sup>[13]</sup>提出一种基于 Lattice-LSTM 的模型,通过结合字符信息和词汇信息来进行编码,用于 NER 任务中的实体消歧.

随着预训练语言模型的快速发展,研究者们开始将其应用于命名实体识别领域,显著提升了识别的准确率,特别是在处理多义词、长距离依赖等复杂的语言现象时表现突出. Dai 等人<sup>[14]</sup>使用 BERT-BiLSTM-CRF 模型对中文电子健康记录中的医疗信息进行提取,该模型融合了 BERT 的语义能力,显著提高了命名实体识别的性能. 李华昱等人<sup>[15]</sup>使用引入 Lexicon Adapter 的 LEBERT 模型,实现了关系三元组的自动抽取. Yao 等人<sup>[16]</sup>提出了一种基于 ALBERT-AttBiLSTM-CRF 和迁移学习模型,使用更轻量级的 ALBERT 模型对原始数据进行词嵌入. Bao 等人<sup>[17]</sup>提出一种 ERNIE-BiLSTM-CRF 的命名实体识别模型,以词向量表示实体,改善了传统模型难以准确捕捉特定句子中实体精确表示的问题.

边界扩散是基于扩散模型( Diffusion Models)的概念,尝试从模糊的边界信息中逐步生成清晰的实体边界. 王珍等人<sup>[18]</sup>将卷积字典扩散模型用于眼底图像增强,有效提升了视网膜眼底图像在模糊和噪声条件下的清晰度和诊断准确性. Shen 等人<sup>[19]</sup>提出了一个 DIFFUSIONNER 生成模型,实现了离散文本序列的提取,在推理速度、渐进式边界细化和动态实体采样方面具有较大优势.

在自然语言处理领域,尽管现有的命名实体识别方法在多种任务中取得了显著进展,但这些方法在处理复杂语境和模糊边界时仍存在不足,往往难以有效捕捉实体边界的细微变化. 因此本文通过引入边界扩

散机制到 ERNIE 预训练语言模型的多头注意力机制中,与现有的基于序列标注的模型结构进行有效结合,提出一种创新的 EBC 模型,以解决课程问句中命名实体识别的边界识别难题.该模型通过融合边界信息,使模型更容易在复杂的上下文中定位实体的开始和结束点,从而在复杂任务中提高性能.

## 2 命名实体识别模型

针对 BERT 在处理中文时不易推出被掩盖掉文字的问题,本文选取 ERNIE 模型作为预训练模型,将边界扩散引入到多头注意力机制中,提出一种改进的命名实体识别模型 ERNIE-BMBD-CRF.此模型分为预训练层、特征提取和解码层.首先利用 ERNIE 模型对句子进行预训练,将其映射为词向量,这些词向量作为神经网络的输入.然后通过 BiLSTM 模型提取上下文语义特征,同时将边界扩散引入到多头注意力 MHA 机制中提取局部重要特征,增强实体边界信息捕捉,构成 BMBD 层.最后在 CRF 层计算标签得分,选取最优的标签序列作为输出,完成解码过程.模型结构如图 1 所示.

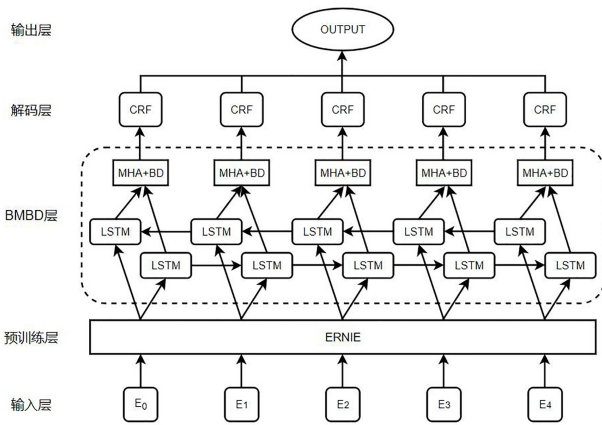


图 1 ERNIE-BMBD-CRF 模型结构图

Fig.1 Structure diagram of ERNIE-BMBD-CRF model

### 2.1 ERNIE 模型

ERNIE 是百度开发的基于 Transformer 架构的预训练语言模型,它通过采用三种不同层次的知识掩码策略,有效促进了模型对语言知识的学习,在多项任务上表现超越了 BERT.在传统的 BERT 模型中,掩码机制对文本中的某些字或词进行随机掩盖,使用 mask 进行标记.ERNIE 模型的掩码策略有意识地选择整个词语、短语或命名实体进行遮盖,如图 2 所示,

这种策略使得模型在预测时能够考虑到整体的上下文信息,从而训练出更加丰富的全局理解能力,学习到更加深入和全面的语义信息.

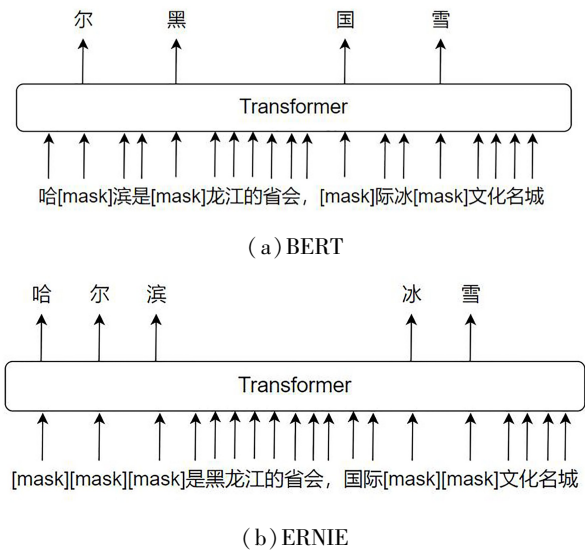


图 2 BERT 和 ERNIE 模型的掩码策略对比

Fig.2 Comparison of mask strategies between BERT and ERNIE models

ERNIE 3.0 模型融合了自回归网络和自编码网络,通过引入丰富的知识整合机制来提升自然语言理解的能力,通过多层 Transformer 结构对输入文本进行编码,每一层的 Transformer 都包含多个自注意力头,这些注意力头可以捕捉到输入序列中不同部分之间的相关性.我们使用 ERNIE3.0 模型来进行词向量表征,将文本输入其中,通过训练生成词向量序列,然后输入至 BMBD 层进行特征提取.

### 2.2 BMBD 层

双向长短期记忆网络 BiLSTM 是一种改进的 RNN,专门设计用于处理序列数据,特别是在自然语言处理和时序预测等任务中表现出色.它在前向和后向两个方向上处理输入序列,能够同时捕捉到序列中每个时间步长的前后文信息,从而更全面地理解整个序列.

LSTM 通过引入三个门控机制(输入门、遗忘门和输出门)来控制信息的流动和记忆,具体公式如下:

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

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

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

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

$$h_t = o_t \cdot \tanh(C_t). \quad (5)$$

公式(1)~(5)中,  $i_t, f_t, o_t$  分别表示输入门、遗忘门、输出门 3 个模块的输出结果,  $C_t, x_t, h_t$  分别表示当前时刻的细胞状态、输入信息、隐藏状态,  $\sigma$  和  $\tanh$  是激活函数,  $W$  表示在不同模块时的权重矩阵,  $b$  是偏置项。

在命名实体识别中, BiLSTM 可以帮助模型识别出实体及其上下文的关系, 从而提高实体识别的准确率. 本文采用双向的 LSTM 网络模型进行特征向量的提取, 计算公式如下:

$$\vec{h}_t = LSTM_{forward}(x_t, \vec{h}_{t-1}). \quad (6)$$

$$\overleftarrow{h}_t = LSTM_{backward}(x_t, \overleftarrow{h}_{t-1}). \quad (7)$$

$$h_t = [\vec{h}_t \oplus \overleftarrow{h}_t]. \quad (8)$$

公式(6)~(8)中,  $\vec{h}_t$  表示前向 LSTM 的隐藏状态,  $\overleftarrow{h}_t$  表示后向 LSTM 的隐藏状态,  $\oplus$  表示向量拼接操作. 这种拼接方式使得 BiLSTM 能够同时捕获序列的前向和后向信息, 从而更好地理解上下文. 随后, 将输出结果传递到多头注意力机制中, 以进一步提取局部特征.

多头注意力机制 MHA 可以增强 BiLSTM 层输出的特征表示, 使得模型能够更加准确地捕捉到词与词之间的长距离依赖关系, 尤其是在处理复杂句子结构时, 多头注意力机制能够有效地理解和表示句子中各个部分的相互关系. 通过结合多头注意力机制, 模型能够在更高的层次上处理和理解输入序列, 提升对序列数据的建模能力和预测准确性.

MHA 通过多个不同的注意力头同时处理输入序列, 从多个角度计算注意力分数, 其注意力函数为:

$$Attention(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V. \quad (9)$$

公式(9)中,  $Q, K, V$  表示输入词向量的矩阵,  $d_k$  表示键向量的维度.

$$Head_i = Attention(QW_{Q_i}, KW_{K_i}, VW_{V_i}). \quad (10)$$

$$MultiHead(Q, K, V) = Concat(Head_1 \dots Head_n) W_0. \quad (11)$$

公式(10)中,  $W_{Q_i}, W_{K_i}, W_{V_i}$  是第  $i$  个注意力头的权重矩阵. 公式(11)中, 通过 Concat 函数将  $n$  个头的输出拼接起来,  $W_0$  是输出层的线性变换矩阵.

每个注意力头独立计算, 分别生成自己的查询 ( $Q$ )、键 ( $K$ ) 和值 ( $V$ ) 矩阵. 通过对  $Q$  和  $K$  的点积计算

注意力权重, 再将这些权重应用于  $V$ , 得到各个头的加权求和结果. 这些独立计算的结果可以捕捉输入序列中不同方面的依赖关系, 提供不同的上下文信息. 将多个注意力头的输出向量进行拼接, 并通过一个额外的线性变换来整合信息, 得到最终的注意力表示.

利用公式(12)计算噪声边界和多头注意力输出的加权求和结果, 并将其传入 ReLU 激活函数中进行非线性变换, 逐步优化序列中不同部分的边界信息, 使模型能够更好地捕捉到序列中的实体边界, 增加模型的表达能力.

$$R(i) = ReLU(\alpha \cdot N(i) + \beta \cdot A(i)). \quad (12)$$

其中,  $\alpha$  和  $\beta$  是可学习的权重参数,  $N(i)$  是第  $i$  个位置的噪声边界信息,  $A(i)$  是第  $i$  个位置的多头注意力输出结果.

### 2.3 CRF 层

在 NER 序列标注任务中, 输出的标签不仅取决于当前时间步的特征, 还受到前后标签的影响. 例如, 在标注人名、地名等实体时, 通常需要满足某些标签规则, 如“B-LOC”(地名的开始)后面应接“I-LOC”(地名的内部), 而不应接“B-PER”(人名的开始)或“O”(非实体), 举例来说, “北、京、市”这三个字的标签应当依次是“B-LOC, I-LOC, I-LOC”. CRF 层可以通过定义状态转移矩阵来明确地建模标签之间的依赖关系, 从而防止出现不合理的标签序列.

假设输入序列为  $X = (x_1, x_2, \dots, x_n)$ , 对应的预测标签序列为  $Y = (y_1, y_2, \dots, y_n)$ , 计算标签序列得分公式为:

$$S(X, Y) = \sum_{i=0}^n A_{y_i, y_{i+1}} + \sum_{i=1}^n P_{i, y_i}. \quad (13)$$

公式(13)中,  $A$  是转移矩阵,  $A_{y_i, y_{i+1}}$  表示标签  $y_i$  转移到标签  $y_{i+1}$  的分数;  $P_{i, y_i}$  表示输入序列第  $i$  个字对应的标签  $y_{i+1}$  的分数. 接着计算预测序列  $Y$  的概率, 计算公式为:

$$P(Y | X) = \frac{e^{S(X, Y)}}{\sum_{\tilde{Y} \in \tilde{Y}_X} e^{S(X, \tilde{Y})}}. \quad (14)$$

公式(14)中,  $\tilde{Y}$  是真实标签序列,  $\tilde{Y}_X$  是所有可能的标签序列集合. 最后通过 Viterbi 算法遍历所有可能的标签序列, 找到最优的标签序列  $Y^*$ , 完成解码过程. 如公式(15)所示:

$$Y^* = \operatorname{argmax}_{\tilde{Y} \in \tilde{Y}_X} S(X, \tilde{Y}). \quad (15)$$

### 3 实验结果与分析

#### 3.1 实验数据

本实验选取了 CLUENER2020<sup>[20]</sup> 和 MSRA<sup>[21]</sup> 两个权威的公开中文领域数据集和自建课程语料数据集作为实验基准. 我们从《大学计算机: 计算思维与信息素养》<sup>[22]</sup> 和《人机交互》<sup>[23]</sup> 两本教材中随机选取了 1 426 条语句, 按照 7:2:1 的比例划分为训练集、验证集和测试集, 利用 YEDDA 标注工具<sup>[24]</sup>, 采用 BIO 标注法<sup>[25]</sup> 进行人工标注. B 表示该词语是一个命名实体的开始, I 表示该词语是一个命名实体的内部, O 表示该词语不属于任何命名实体.

#### 3.2 实验环境与参数设置

本实验使用 python 编程, 具体实验环境设置如表 1 所示.

表 1 实验环境设置

Table 1 Experimental environment setup

实验环境	设置
操作系统	Ubuntu22.04
CPU	14 vCPU Intel(R) Xeon(R) Platinum 8362 CPU @ 2.80 GHz
GPU	NVIDIA RTX 3090
CUDA	Cuda12.1
PyTorch	2.3.0
Pycharm	PyCharm 2022.1.4
Python	3.12

为了确保实验的有效性, 实验中的训练参数采用统一设置, 最大输入长度为 128, 批次大小设置为 50,

表 2 在 CLUENER2020 数据集上的实验结果

Table 2 Experimental results on CLUENER2020 dataset

模型	Accuracy/%	Precision/%	Recall/%	F1/%
BERT-BiLSTM-CRF	94.64	81.32	79.23	81.66
BERT-BiGRU-CRF	94.97	80.59	82.45	81.87
ERNIE-AttBiLSTM-CRF	95.22	84.33	83.57	84.05
EBC(本文方法)	<b>97.45</b>	<b>86.23</b>	<b>89.25</b>	<b>87.45</b>

表 3 在 MSRA 数据集上的实验结果

Table 3 Experimental results on MSRA dataset

模型	Accuracy/%	Precision/%	Recall/%	F1/%
BERT-BiLSTM-CRF	97.29	94.45	93.88	94.74
BERT-BiGRU-CRF	96.87	96.73	95.61	95.18
ERNIE-AttBiLSTM-CRF	98.92	97.85	97.27	97.23
EBC(本文方法)	<b>99.61</b>	<b>98.43</b>	<b>98.54</b>	<b>98.48</b>

训练轮次为 10 次, 学习率为 5e-5.

#### 3.3 评价指标

本文采取准确率 Accuracy、精确率 Precision、召回率 Recall、F1 值四个值来评价实验结果. 各指标的计算公式如公式 (16) ~ (19) 所示, 其中 TP 表示真正例, TN 表示真反例, FP 表示假正例, FN 表示假反例.

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN}. \quad (16)$$

$$Precision = \frac{TP}{TP + FP}. \quad (17)$$

$$Recall = \frac{TP}{TP + FN}. \quad (18)$$

$$F1 = \frac{2Precision * Recall}{Precision + Recall}. \quad (19)$$

#### 3.4 实验结果对比

本文模型和 BERT-BiLSTM-CRF、BERT-BiGRU-CRF、ERNIE-AttBiLSTM-CRF 等三类模型进行实验对比. 在 CLUENER2020 和 MSRA 数据集上的实验结果分别如表 2、表 3 所示. 可以看出, 本文提出的 EBC 模型在两个数据集上的表现优于其他对比算法, 在 CLUENER2020 数据集上, EBC 模型的准确率、精确性、召回率和 F1 均高于对比模型. 在 MSRA 数据集上, EBC 模型的表现更为突出, 各项指标均有明显提升, 进一步证明了 EBC 模型在处理中文命名实体识别任务时的高效性和准确性.

在本文自建课程数据集上的实验结果如表 4 所示. EBC 方法的准确率和 F1 分数分别为 94.98% 和 81.49%, 虽然略低于两个公开数据集上的表现, 但与

其他模型相比, EBC 方法在知识点识别方面仍然具有较好的性能.

表 4 在课程语料数据集上的实验结果

Table 4 Experimental results on course corpus dataset

模型	Accuracy/%	Precision/%	Recall/%	F1/%
BERT-BiLSTM-CRF	93.29	78.82	70.95	74.31
BERT-BiGRU-CRF	92.87	80.19	73.76	76.56
ERNIE-AttBiLSTM-CRF	93.52	81.97	74.61	79.33
EBC(本文方法)	<b>94.98</b>	<b>83.29</b>	<b>76.76</b>	<b>81.49</b>

综合实验结果, 在中文命名实体识别任务中, ERNIE 性能优于 BERT. 通过采用多头注意力机制, 模型能够更有效地处理 BiLSTM 层的输出, 从而更精准地识别词语间的长距离依赖关系. 此外, 边界扩散的引入提升了模型对实体边界信息的捕捉能力, 有助于更准确地识别序列中的边界信息. 综合上述分析可得, 本文所使用的模型在命名实体识别任务中提高了准确率与 F1 值.

### 3.5 消融实验

为了验证不同模块对 ERNIE-BMBD-CRF (EBC) 模型在课程问句命名实体识别任务中的贡献, 我们设计了消融实验来分析模型的性能, 分别移除 BMBD-CRF 层和 CRF 层, 并在课程语料数据集上进行对比实验, 实验结果如表 5 所示. 其中, 可以看出 BMBD 层有效增强了上下文的语义表征, 而 CRF 层则有助于捕捉标签之间的依赖关系, 从而获得全局最优的序列标签分配.

表 5 消融实验结果

Table 5 Results of ablation experiment

模型	Accuracy/%	Precision/%	Recall/%	F1/%
-BMBD-CRF	92.11	76.43	70.82	73.75
-CRF	94.37	83.01	75.49	80.81
EBC(本文方法)	<b>94.98</b>	<b>83.29</b>	<b>76.76</b>	<b>81.49</b>

## 4 结论

本文提出了一种基于 EBC 模型的课程命名实体识别方法, 解决了传统方法中因忽略上下文联系而不易推出被掩盖掉文字的问题. 首先利用 ERNIE 预训练语言模型进行文本表征, 然后通过 BiLSTM 提取上下文语义特征, 将边界扩散机制引入到多头注意力中增强实体边界信息捕捉, 最后在 CRF 模型中进行序列标签解码, 得到最优的标签序列. 实验结果表明, 该模型在 CLUENER2020、MSRA 两个公开数据集和自建课程语料数据集上的表现均优于其他对比模型.

未来我们计划将本文研究的命名实体识别方法融入课程智能问答系统中, 旨在通过智能化手段辅助学生学习, 提升学生的学习效率和质量.

## 参考文献

- [1] XUE M G, YU B W, ZHANG Z Y, et al. Coarse-to-fine pre-training for named entity recognition[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). Online. Stroudsburg, PA, USAACL, 2020:6345-6354.
- [2] FU G H, LUKE K K. Chinese named entity recognition using lexicalized HMMs[J]. ACM SIGKDD Explorations Newsletter, 2005, 7(1):19-25.
- [3] LAFFERTY J, MCCALLUM A, PEREIRA F C N. Conditional random fields: probabilistic models for segmenting and labeling sequence data[J]. Icm1 '01; Proceedings of the Eighteenth International Conference on Machine Learning, 2001(6):282-289.
- [4] BERGER A L, PIETRA S D, PIETRA V D. A maximum entropy approach to natural language processing[J]. Computational linguistics, 1996, 22(1):39-71.
- [5] CORTES C, VAPNIK V. Support-vector networks[J]. Machine Learning, 1995, 20(3):273-297.
- [6] CHUA L O, ROSKA T. The CNN paradigm[J]. IEEE Transactions on

- Circuits and Systems I: Fundamental Theory and Applications, 1993, 40 (3): 147-156.
- [7] CHO K, VAN MERRIENBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). Doha, Qatar. Stroudsburg, PA, USA: ACL, 2014: 1-14.
- [8] YU Y, SI X S, HU C H, et al. A review of recurrent neural networks: LSTM cells and network architectures[J]. Neural Computation, 2019, 31(7): 1235-1270.
- [9] LEFEBVRE G, BERLEMONT S, MAMALET F, et al. BiLSTM-RNN based 3D gesture classification[M]//Artificial Neural Networks and Machine Learning-ICANN 2013. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013: 381-388.
- [10] DEVLIN J, CHANG M W, LEE K, et al. BERT: Pre-training of deep bidirectional transformers for language understanding[EB/OL]. 2018: 1810.04805. <https://arxiv.org/abs/1810.04805v2>.
- [11] SUN Y, WANG S H, LI Y K, et al. ERNIE: Enhanced representation through knowledge integration[EB/OL]. 2019: 1904.09223. <https://arxiv.org/abs/1904.09223v1>.
- [12] HUANG Z H, XU W, YU K. Bidirectional LSTM-CRF models for sequence tagging[EB/OL]. 2015: 1508.01991. <https://arxiv.org/abs/1508.01991v1>.
- [13] ZHANG Y, YANG J. Chinese NER using lattice LSTM[EB/OL]. 2018: 1805.02023. <https://arxiv.org/abs/1805.02023v4>.
- [14] DAI Z J, WANG X T, NI P, et al. Named entity recognition using BERT BiLSTM CRF for Chinese electronic health records[C]//2019 12th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI). Suzhou, China: IEEE, 2019: 1-5.
- [15] 李华昱, 付亚凤, 闫阳, 等. 基于 LEBERT 的多模态领域知识图谱构建[J]. 计算机系统应用, 2022, 31(11): 79-90.
- [16] YAO L G, HUANG H S, WANG K W, et al. Fine-grained mechanical Chinese named entity recognition based on ALBERT-AttBiLSTM-CRF and transfer learning[J]. Symmetry, 2020, 12(12): 1986.
- [17] BAO Z Y, ZHANG L J, LU Z Y. Research on named entity recognition based on ERNIE-BiLSTM-CRF[C]//2023 International Conference on Computers, Information Processing and Advanced Education (CI-PAE). Ottawa, ON, Canada: IEEE, 2023: 523-527.
- [18] 王珍, 霍光磊, 兰海, 等. 基于卷积字典扩散模型的眼底图像增强算法[J]. 中国图象图形学报, 2024, 29(8): 2426-2438.
- [19] SHEN Y L, SONG K T, TAN X, et al. DiffusionNER: Boundary diffusion for named entity recognition[EB/OL]. 2023: 2305.13298. <https://arxiv.org/abs/2305.13298v1>.
- [20] XU L, TONG Y, DONG Q Q, et al. CLUENER2020: Fine-grained named entity recognition dataset and benchmark for Chinese[EB/OL]. 2020: 2001.04351. <https://arxiv.org/abs/2001.04351v4>.
- [21] LEVOW G A. The third international chinese language processing bakeoff: word segmentation and named entity recognition[C]//Meeting of the Association for Computational Linguistics. Association for Computational Linguistics, 2006: 108-117.
- [22] 战德臣, 张丽杰. 大学计算机: 计算思维与信息素养[M]. 3 版. 北京: 高等教育出版社, 2019.
- [23] 布茨, 克鲁格. 人机交互[M]. 陈雅茜, 译. 北京: 科学出版社, 2019.
- [24] YANG J, ZHANG Y, LI L W, et al. YEDDA: A lightweight collaborative text span annotation tool[J]. Proceedings of ACL 2018, System Demonstrations, 2018: 31-36.
- [25] 黄晴雁, 牟永敏. 命名实体识别方法研究进展[J]. 现代计算机(专业版), 2018, 24(35): 12-17+22.
- (责任编辑: 张阳, 殷锋, 付强, 和力新, 肖丽; 英文编辑: 周序林, 郑玉才)