

CCL23-Eval 任务3系统报告：基于旋转式位置编码的实体分类在汉语框架语义解析中的应用

李作恒¹, 郭炫志¹, 乔登俭¹, 吴钊¹

(1.四川久远银海软件股份有限公司, 四川省 成都市 610023)

摘要

汉语框架语义解析 (Chinese Frame Semantic Parsing, CFSP) 是中文自然语言处理领域中的一项重要任务, 其目标是从句子中提取框架语义结构, 实现对句子中涉及到的事件或情境的深层理解。本文主要研究子任务框架识别和论元角色识别, 自然语言处理中常用的方法在框架识别和论元角色识别中会丢失目标词与整体句子之间的位置信息关系以及目标词内部信息, 对此本文提出基于旋转式位置编码的实体分类模型对实体之间计算注意力然后进行分类, 并在天池“CCL2023-Eval 汉语框架语义解析评测”比赛上获得A、B榜第一名的成绩¹。

关键词: 框架语义解析; 实体分类; 旋转式位置编码

System Report for CCL23-Eval Task 3: Application of Entity Classification Model Based on Rotary Position Embedding in Chinese Frame Semantic Parsing

LI Zuoheng¹, GUO Xuanzhi¹, QIAO Dengjian¹, WU Fan¹

(1. JIU YUAN YIN HAI, Sichuan, Chengdu 610023, China)

Abstract

Chinese Frame Semantic Parsing is an important task in the Chinese Natural Language Processing (NLP). The goal is to extract the frame semantic structure from sentences and get deep understanding of the events or situations involved in sentences. This paper mainly studies sub-tasks Frame Identification and Role Identification. The common classification methods in NLP will lose the position information relationship between the target word and the whole sentence as well as the internal information of the target word in Frame Identification and Role Identification. In response to this, this paper proposes Entity Classification Model Based on Rotary Position Embedding to calculate attention between entities and then classify them. We achieved first place on the A and B rankings in the "CCL2023-Eval Chinese Framework Semantic Analysis Evaluation" on Tianchi platform.

Keywords: Frame Semantic Parsing, Entity Classification, Rotary Position Embedding

¹<https://tianchi.aliyun.com/competition/entrance/532083/introduction>

1 引言

汉语框架语义解析是一种以框架语义学(Charles J. Fillmore, 1982)为基础, 基于汉语框架网 (Chinese FrameNet, CFN) (刘开瑛, 2008)的语义表示和标注, 通过对句子提取框架语义结构(Daniel Gildea et al., 2002), 从而达到语义分析目的的语言研究方法。框架语义解析在阅读理解(Shaoru Guo et al., 2020; Shaoru Guo et al., 2020)、文本摘要(Yong Guan et al., 2021; Yong Guan et al., 2021)、关系抽取(Hongyan Zhao et al., 2020)等下游任务有着重要意义。框架语义解析的基本数据类型如下: 对于例句“这届外企交易会有六百多家企业参展”, “有”和“参展”分别会作为触发词激起两个框架“共计”和“参与”。对于框架“共计”, 框架元素为“属性”和“值”, 论元对应着“这届外企交易会”和“六百多家企业”; 而对于框架“参与”, 框架元素则为“事件”和“参与者们”, 如图1所示。框架语义解析能够高效且准确的提炼出句子的核心语义, 是自然语言处理 (Natural Language Processing, NLP) 中重要的一种语义分析方法。

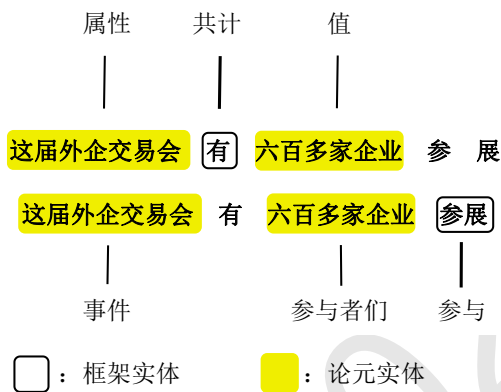


Figure 1: CFN1.0数据样例

汉语框架网 (郝晓燕 et al., 2007) 是一个依据汉语真实语料来供计算机使用的汉语语义知识库, 其以Fillmore提出的框架语义学为基础并参照了加州大学伯克利分校的FrameNet(Charles J. Fillmore et al., 1998)工程。汉语框架网由框架库、句子库和词元库组成, 为了更好的理解汉语框架语义解析, 下面主要介绍框架库; **框架** 是跟一些激活性语境相一致的一个结构化的范畴系统, 是储存在人类认知经验中的图式化情境; **框架元素** 又被称为角色, 其体现的是框架的语义参与者。框架元素所对应的词元被称为论元。框架库中的每个框架主要由框架和框架元素的基本定义组成。表1对“参与”框架进行了简略描述。

本文涉及的汉语框架语义解析的子任务有: 框架识别 (Frame Identification)、论元范围识别 (Argument Identification) 和论元角色识别 (Role Identification)¹。**框架识别** 任务是框架语义学研究中的核心任务, 其要求根据给定句子中目标词的上下文语境, 为其寻找一个可以激活的框架。框架识别任务可以帮助计算机识别出句子中的关键信息和语义框架, 从而更好地理解句子的含义; **论元范围识别** 任务是给定一条汉语句子及目标词, 在目标词已知的条件下, 从句子中自动识别出目标词所搭配的语义角色的边界。该任务的主要目的是确定句子中每个目标词所涉及的论元 (即框架元素) 在句子中的位置; **论元角色识别** 任务旨在确定句子中每个论元对应的框架元素, 即每个论元在所属框架中的语义角色。论元角色识别任务对于许多自然语言处理任务都是至关重要的, 例如信息提取、关系抽取和机器翻译等。它可以帮助计算机更好地理解句子的含义, 从而更准确地提取句子中的信息, 进而帮助人们更好地理解文本。

2 相关工作

框架语义解析的主要研究之一是SemEval-2007国际语义评测会议中基于FrameNet语料库提出的“frame semantic structure extraction”任务(Collin F Baker et al., 2007), 即框架语义结构抽取任务。C. A. Bejan等(Cosmin Adrian Bejan et al., 2007)利用SVM和最大熵模型实现了一个语义结构抽取系统; D. Das(Dipanjan Das et al., 2013)使用快速对偶分解算法等方法建模。对

¹<https://tianchi.aliyun.com/competition/entrance/532083/information>

框架名	参与 (Participation)	
定义	某事件有多名参与者。在该事件中，多名参与者或以同等重要的地位出现，或以参与者1比参与者2更为重要的形式出现。如果参与者参与该事件是有意图的，那么在多名参与者之间通常还存在一个共同目的。然而，有可能所表达出来的目的只适用于参与者1。	
框架元素	事件(Event)	该框架元素指有多名参与者有目的或无目的参与的事件。
	机构(Institution)	依照惯例，与事件相关的团体，场所，或者机构。
	参与者1(Participant 1)	从语法的角度来说，参与者1在有多名参与者参与的事件中要比其它参与者更为重要一些。
	参与者2(Participant 2)	从语法上讲，参与者2在有多名参与者参与的事件中重要性相对弱些。
	参与者们(Participants)	参与某事件的一些人或实体集。
	参与程度 (Degree of involvement)	参与者1参与事件的程度。
	时量(Duration)	这个框架元素描述了参与事件的时间长度（通常作为一个介词短语出现）。
	方式(Manner)	对于没有被一些更为具体的框架元素所涵盖的事件（或状态）的描述。
	方法(Means)	参与者1或参与者的一个有意行为，该行为有助于完成该事件。
	处所(Place)	有多名参与者参与的事件所发生的空间场所。
	目的(Purpose)	参与者或参与者1试图通过实施与事件相关的行为来达到的目的。
	时间(Time)	有多名参与者参与的事件发生的时间。

Table 1: “参与”框架的描述简表

于汉语框架语义解析，Xue等(N Xue et al., 2005)通过最大熵分类器进行语义标注；李济洪(李济洪, 2010)等通过“OBI数据类型”标注和条件随机向量场模型来挑选特征模板；石佼等(石佼 et al., 2014)采用“OBI数据类型”标注和基于贪心策略的特征选择算法选出最优特征模板。

这 届 外 企 交 易 会 有 六 百 多 家 企 业 参 展
 O O O O O O O B_A O O O O O O B_P I_P

Figure 2: “OBI”型数据

在自然语言处理任务中，“框架识别”和“论元角色识别”属于对于实体的“分类”任务，“论元范围识别”属于对于实体的“抽取”任务。对于分类方法，以预训练模型BERT(Devlin et al., 2019)为例，有对句子的分类token: [CLS]进行分类预测和对实体token分类进行预测。对于[CLS]分类，会对目标词添加提示词，如：“这届外企交易会有六百多家企业< t >参展< /t >”。对于抽取方法，有“OBI”型数据的token预测抽取方法和“span”型数据的头尾预测抽取方法等。“OBI”型数据是对句子所有的字进行标注：目标词的首字标注为“B.label”，目标词的

其他内部字标注为“l.label”，句子中的其余字标注为“O”，如图2所示。“OBI”型数据的预测是对每个字的token进行多分类预测，如果数据有“L”类分类标签，则每个token会有“2L + 1”类标签。“OBI”型数据的预测方法常用的模型有“Embedding + BiLSTM + CRF(Zhiheng Huang et al., 2015)”等。“span”型数据会标注一个“头尾矩阵”：**H-T**，其中目标词的头-尾处标注为对应的“label_index”，矩阵中其他位置标注为“0”，如图3(a)所示。此外还可以如此标注：对于有L个label类的数据，会产生L个头尾矩阵，对目标词所在类第“label_index”个矩阵的头-尾处标注“1”，其他位置以及其他类矩阵标注为“0”，如图3(b)(c)所示。“span”型数据的预测方法常用的模型有GlobalPointer(Jianlin Su et al., 2022)等。

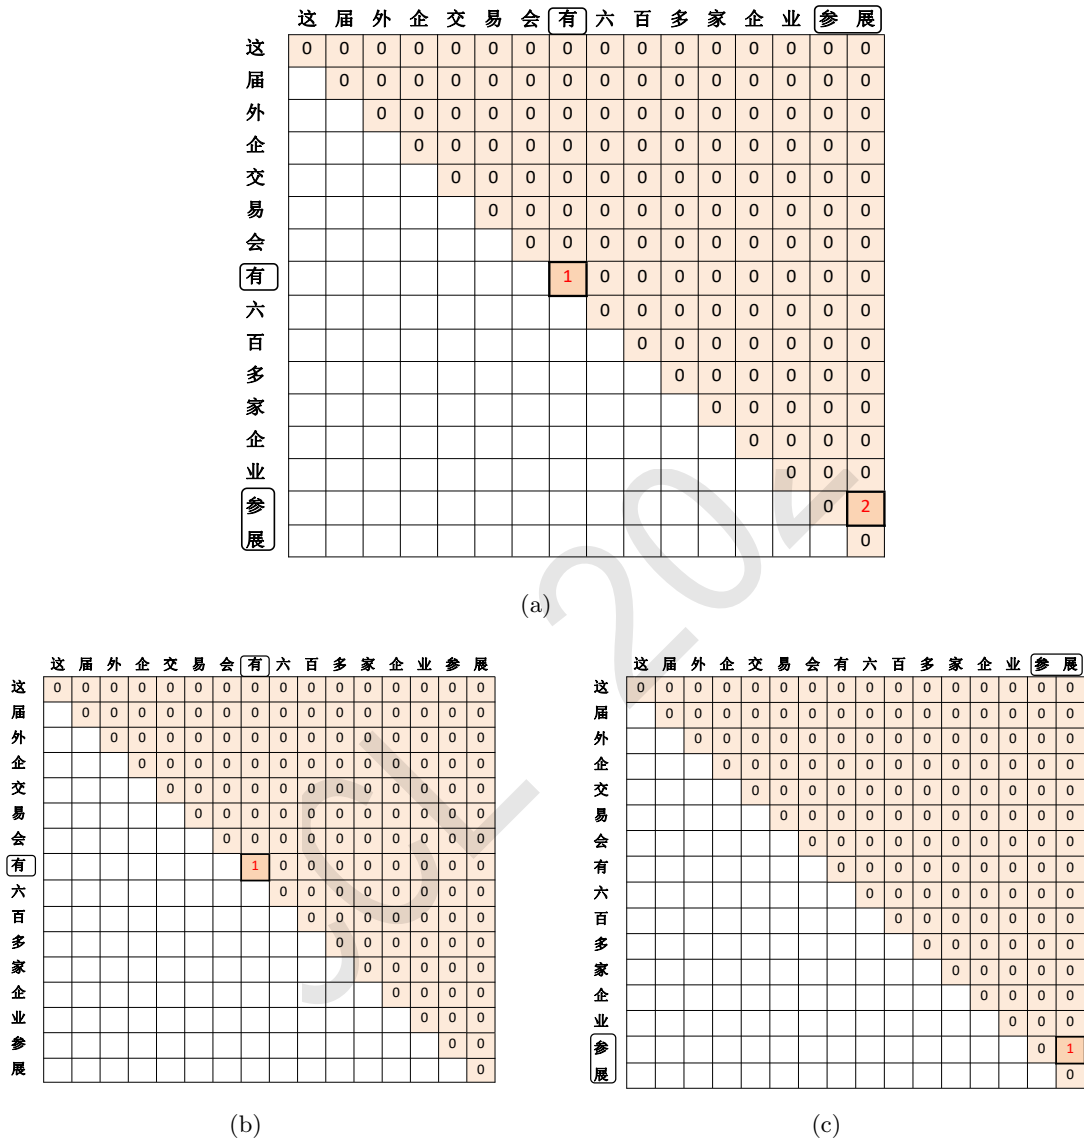


Figure 3: “span”型数据

对于框架识别和论元角色识别此类实体分类任务，与传统机器学习和深度学习模型相比，使用了如BERT的预训练语言模型极大的提高了分类效果。在已有方法中，“提示词+句子分类”实现实体分类的方法会忽略实体与整体句子本身的相对信息，使得实体对于上下文的理解上有所不足。对于“实体token分类”方法多，常采用实体首token分类、实体首尾token取平均分类以及实体所有token取平均分类，其中“CCL2023-Eval 汉语框架语义解析评测”官方baseline就采用了实体首token分类的方法，此类方法对比句子分类体现了实体的位置信息，利用了实体对应上下文的信息，但不足之处在于没有充分利用实体内部词与词之间的关系。为了增强实体分类中实体内部之间信息关系的利用，本文提出了新的实体分类模型，并在“CCL2023-Eval 汉语框

架语义解析评测“比赛中取得了A、B榜第一名的成绩。本文将在第4节对该实体分类模型进行详细介绍，并在第6节与已有其他方法进行对比实验。

3 汉语框架语义解析任务描述

框架识别：给定句子 $s = \langle w_1, w_2, \dots, w_n \rangle$ 以及目标词 t ，设所有语义框架集合 $F = \{f_1, f_2, \dots, f_m\}$ ，为目标词 t 分配一个最合适的语义框架 f_t ，即在已给出 s, t 的条件下，找到 f_t 使得概率 P 最大，具体公式为

$$f_t = \arg \max_{1 \leq j \leq m} P(f_j | s, t).$$

论元范围识别：给定句子 $s = \langle w_1, w_2, \dots, w_n \rangle$ 目标词 t 和框架 f ，在句子的所有词元集合 $T = \{t_1, t_2, \dots, t_N\}$ 中识别出论元集合 \hat{T} ，具体公式为

$$\begin{cases} \hat{t} \in \hat{T}, & \text{if } P(\hat{t} | s, t, f) \geq \theta; \\ \hat{t} \notin \hat{T}, & \text{if } P(\hat{t} | s, t, f) < \theta. \end{cases}, \hat{t} \in T.$$

其中 θ 为阈值。

论元角色识别：根据已给出的目标词 t 、框架 f 和论元 \hat{t} ，在框架 f 所支配的框架元素集合 $R = \{r_1, r_2, \dots, r_M\}$ 中选择最适合的，即找到 r_t 使得概率 P 最大，具体公式为

$$r_t = \arg \max_{1 \leq i \leq M} P(r_i | s, t, \hat{t}).$$

4 基于旋转式位置编码的实体分类模型

旋转式位置编码（RoPE）（Jianlin Su et al., 2022）的核心思想是给句子添加特殊的位置编码，为每个token添加对应的绝对位置信息，并且此位置编码在计算注意力时还可以体现出出token与token的相对位置信息。以BERT为例，BERT输出一个hidden_token:

$$[[CLS], token_0, token_1, \dots, token_n, [SEP]]$$

其中

$$[CLS], [SEP], token_i \in \mathbb{R}^d, i \leq n, d = 768.$$

将hidden_token通过线性变换得到维度为inner_dim的多分类向量，其中分类数 l 取决于相应任务label的分类数目:

$$\begin{aligned} & [c^0, t_1^0, t_2^0, \dots, t_n^0, s^0] \\ & [c^1, t_1^1, t_2^1, \dots, t_n^1, s^1] \\ & \dots \\ & [c^l, t_1^l, t_2^l, \dots, t_n^l, s^l] \end{aligned}$$

其中

$$c^j, s^j, t_i^j \in \mathbb{R}^{inner_dim}, i \leq n, j \leq l.$$

最后，引入RoPE函数与分数函数:

$$\begin{aligned} R(t_i^j) &= \mathcal{R}_i t_i^j, \\ S_j(t_i^j, t_{i'}^j) &= R(t_i^j) \times R(t_{i'}^j) = (\mathcal{R}_i t_i^j)^T (\mathcal{R}_{i'} t_{i'}^j). \end{aligned}$$

基于RoPE的特性，可以得到

$$S_j(t_i^j, t_{i'}^j) = (\mathcal{R}_i t_i^j)^T (\mathcal{R}_{i'} t_{i'}^j) = t_i^{jT} \mathcal{R}_{i-i'} t_{i'}^j.$$

该方法的整体框架如图4所示。




Figure 4: 基于RoPE的实体分类框架图

5 整体模型介绍

5.1 基本概念模型

分类任务: 对于句子 $s = \langle w_1, w_2, \dots, w_n \rangle$ 、目标词 t 和分类标签 f , $p(f|s, t)$ 表示预测 t 的类别为 f 的概率, 目标函数为

$$\max_f p(f|s, t).$$

抽取任务: 对于句子 $s = \langle w_1, w_2, \dots, w_n \rangle$ 、目标词 t 和目标词类 f , 目标是识别出词元 $\langle w_i, \dots, w_j \rangle$, $\mathbf{Y}(\langle w_i, \dots, w_j \rangle | s, t, f)$ 表示预测由字 w_i 到 w_j 所组成的词是否为所需实体, 取值为0和1, 目标函数为

$$\begin{cases} \mathbf{Y}(\langle w_i, \dots, w_j \rangle | s, t, f) = 1, & \langle w_i, \dots, w_j \rangle \in \mathbf{P}; \\ \mathbf{Y}(\langle w_i, \dots, w_j \rangle | s, t, f) = 0, & \langle w_i, \dots, w_j \rangle \in \mathbf{Q}. \end{cases}$$

其中 \mathbf{P} 为所需实体词集合, \mathbf{Q} 为其他非实体词集合。

5.2 概率估计模型

对于分类任务, 本文采用如下方法近似估计概率函数 $p(f|s, t)$: 对于目标词 t , 提取首尾字信息 w_{t_i} 和 w_{t_j} , 通过Embedding函数 \mathbf{E} 投影到高维特征空间分别得到特征向量 $\mathbf{w}_i^f = \mathbf{E}(w_{t_i}, s, f)$ 和 $\mathbf{w}_j^f = \mathbf{E}(w_{t_j}, s, f)$, 然后计算相对信息 $\mathbf{I}(\mathbf{w}_i^f, \mathbf{w}_j^f)$, 概率函数 $p(f|s, t)$ 则可如下计

算:

$$p(f|s, t) \approx \frac{\exp\left(\mathbf{I}(\mathbf{E}(w_{ti}, s, f), \mathbf{E}(w_{tj}, s, f))\right)}{\sum_{\tilde{f}} \exp\left(\mathbf{I}(\mathbf{E}(w_{ti}, s, \tilde{f}), \mathbf{E}(w_{tj}, s, \tilde{f}))\right)}.$$

对于抽取任务, 本文采用预测一个实体的头索引 r_i 和尾索引 r_j 的方法: 对于任意一对头尾索引(边界索引) i, j , 通过分数函数 \mathbf{S} 计算相对信息得分, 预测函数 $\mathbf{Y}(\langle w_i, \dots, w_j \rangle | s, t, f)$ 可如下计算:

$$\mathbf{Y}(\langle w_i, \dots, w_j \rangle | s, t, f) \approx \mathbf{Boolean}\left(\mathbf{S}(\mathbf{E}(w_i, s, f), \mathbf{E}(w_j, s, f)) \geq \theta\right),$$

其中 θ 为超参数阈值, $\mathbf{Boolean}(\cdot)$ 为布尔值函数。

本文采用“预训练语言模型PLM + 微调”的模型结构, 使用PLM作为Embedding函数。下面详细介绍做分类任务和抽取任务的方法。

5.3 子任务对应的方法

框架识别: 该任务数据已给出了目标词信息, 采用基于RoPE的实体分类方法。对于已给出的目标词, 即目标词的边界索引 $target_start$ 与 $target_end$, 计算出对应的分数:

$$S_j(t_{target_start}^j, t_{target_end}^j), j \in d_{frame}.$$

其中 d_{frame} 为框架种类数。

$$target_frame = \arg \max_{j \in d_{frame}} [\text{softmax}(\mathbf{S}(\mathbf{t}_{target_start}, \mathbf{t}_{target_end}))].$$

其中

$$\mathbf{S}(\mathbf{t}_{target_start}, \mathbf{t}_{target_end}) = [S_0(t_{target_start}^0, t_{target_end}^0), \dots, S_j(t_{target_start}^j, t_{target_end}^j), \dots].$$

损失函数为CrossEntropyLoss. 即

$$Loss_{FI} = CrossEntropyLoss\left(\mathbf{S}(\mathbf{t}_{target_start}, \mathbf{t}_{target_end}), target_labels\right).$$

论元范围识别: 对于目标词, 在输入BERT前先加入提示词 $\langle t \rangle$ 和 $\langle \backslash t \rangle$ 于目标词两侧, 再将已加入提示词的句子输入BERT进行计算。对于此任务, 目的是输出论元角色词的范围, 即 $role_start$ 和 $role_end$ 。采用1个分类的GlobalPointer模型作为下游模型:

$$S(t_i, t_{i'}), i \leq i' < \max_len.$$

其中 \max_len 为hidden_token的长度, 最终输出为:

$$\mathbf{H-T}_{i,i'} = \begin{cases} 1, & \text{if } S(t_i, t_{i'}) \geq 0 \\ 0, & \text{if } S(t_i, t_{i'}) < 0 \end{cases}. \quad (1)$$

损失函数为GlobalPointer模型的损失函数:

$$Loss_{AI} = \log \left(1 + \sum_{(i,i') \in P} e^{-S(t_i, t_{i'})} \right) + \log \left(1 + \sum_{(i,i') \in Q} e^{S(t_i, t_{i'})} \right).$$

其中 P 为所有实体首尾索引组成的集合, Q 为其他非实体首尾集合。

论元角色识别: 将已加入提示词的句子输入BERT后使用基于RoPE的实体分类方法对论元进行分类。

$$Loss_{RI} = CrossEntropyLoss\left(\mathbf{S}(\mathbf{t}_{role_start}, \mathbf{t}_{role_end}), role_labels\right).$$

6 实验与分析

表2为“CCL2023-Eval 汉语框架语义解析评测”官方发布的对于 task1（框架识别）、task2（论元范围识别）以及 task3（论元角色识别）在测试集上的baseline测试结果、其他队伍（前5名队伍）以及本文方法提交的测试集上的结果对比，其中

$$score = 0.3 * task1-acc + 0.3 * task2-f1 + 0.4 * task3-f1.$$

Type	score	task1-acc	task2-f1	task3-f1
baseline	67.42	65.10	87.55	54.07
our_model	71.49	74.28	86.33	58.27
team_1	70.27	71.77	87.43	56.28
team_2	69.07	70.59	85.62	55.52
team_3	66.81	65.14	87.75	52.36
team_4	66.46	65.87	87.98	50.76

Table 2: 测试集上结果对比

由表2结果可以看出，本文的实体分类模型在task1和task3上有着较好的效果。

6.1 与baseline的对比

对于task1和task3，官方baseline采用BERT的“BertForTokenClassification”对目标词的首token进行分类。下面我们将在验证集上对比以下三种方法：

1. TokenClassification, baseline;
2. SequenceClassification + prompt, 即对目标词两侧增加提示词;
3. RoPEClassification, 基于旋转式位置编码的实体分类。

Type	task1-acc	task3-acc
TokenClassification	74.00	72.16
SequenceClassification + prompt	72.00	73.03
RoPEClassification	75.45	75.12

Table 3: 分类任务在验证集上的对比

由表3可以看出，RoPE分类的准确率要更高一些，对比句分类方法，token分类和RoPE分类直接关注于目标词本身的信息，减少了其他句中词的干扰使得预测精度上升。对比token分类只利用词首token信息，RoPE分类方法利用特殊的Attention层和其绝对位置信息与相对位置信息兼容的独特编码，提取了整个目标词的内部信息和在句中的相对信息，从而达到了更高的预测精度。

6.2 输出层的选择

对于BERT的输出，本次对比了三种输出情况：最后一层，最后四层，第一层+最后一层，对比如表5所示。

对于分类任务：task1使用L1+L2+L3+L4输出效果更好，task3使用L1输出效果更好。对于抽取任务：task2使用F1+L1输出的准确率更高，使用L1+L2+L3+L4输出的召回率更高，使用L1输出的F1值更高。

Type	task1-acc	task2			task3-acc
		task2-p	task2-r	task2-f1	
L1	75.45	81.35	79.99	80.66	75.12
L1+L2+L3+L4	75.95	79.94	80.89	80.41	74.84
F1+L1	74.25	81.89	78.85	80.34	73.68

Table 4: 最后一层 (L1)、最后四层 (L1+L2+L3+L4) 和第一层+最后一层 (F1+L1) 的验证集结果对比

6.3 模型增强

对抗训练. 本次使用了FGM(Miyato et al., 2016)算法对模型加入对抗训练。FGM的思想为在embedding层对模型反向传播的梯度，在下降的反方向加入一个对抗攻击，从而使得模型训练产生对抗训练的效果，其中对抗攻击的计算方式为：

$$r_{adv} = \epsilon \cdot \frac{g}{\|g\|_2}$$

防止过拟合. 本次使用NoisyTune(Chuhan Wu et al., 2022)方法对模型训练进行防过拟合处理。NoisyTune的思想为在PLM进行微调之前，对参数矩阵增加一个扰动：

$$\tilde{W} = W + U \left(-\frac{\lambda}{2}, \frac{\lambda}{2} \right) \times \text{std}(W).$$

其中 $U(a, b)$ 为 a 到 b 的均匀分布， λ 为超参数， $\text{std}(\cdot)$ 为标准差。

针对本次的三个任务，对比四组方法：基本模型 (model)、加入FGM (FGM)、加入NoisyTune (NoisyTune) 和同时加入FGM和NoisyTune (FGM + NoisyTune)，在验证集上的对比结果如表6所示，其中的输出层结构为task1: L1+L2+L3+L4; task2, task3: L1.

Type	task1-acc	task2			task3-acc
		task2-p	task2-r	task2-f1	
model	75.95	81.35	79.99	80.66	75.12
model + FGM	75.30	82.03	79.51	80.75	73.66
model + NoisyTune	75.65	79.95	80.87	80.41	74.79
model + FGM + NoisyTune	74.75	81.37	80.58	80.97	74.41

Table 5: 基础模型，加入FGM，加入NoisyTune和同时加入FGM和NoisyTune的验证集结果对比

对于task1和task3分类任务，加入FGM和NoisyTune会使得模型效果下降，这是由于两个分类任务更具有“针对性”，更注重训练目标词所对应token的相关参数，而FGM和NoisyTune会对整体的参数进行优化调整，从而在此任务上会对目标词token产生干扰。对于task2抽取任务，加入FGM使得准确率更高，而加入NoisyTune使得召回率更高，同时加入二者会增加鲁棒性和防止过拟合，从而使整体F1值提高。

6.4 其他

BERT模型的参数使用chinese_bert_wwm_ext:

<https://huggingface.co/hfl/chinese-bert-wwm-ext/tree/main>

RoPE使用的GP_Linker模型的RoPE部分:

https://github.com/xhw205/GPLinker_torch

7 总结

本文以“已有实体分类模型对实体内部信息利用不充分”的缺点为动机，提出了利用旋转式位置编码增强实体内部信息提取的实体分类模型，在对比实验中均取得了最好的效果。并且将该模型运用在了“CCL2023-Eval 汉语框架语义解析评测”比赛的框架识别和论元角色识别任务上，取得了这两项任务第一的成绩。本文不足之处在于没有充分发挥RoPE实体分类模型的优势，在论元范围识别任务上使用的方法相比于其他队伍效果欠佳，因此将RoPE实体分类模型与其他效果更好的实体抽取模型结合仍是值得研究的方向。

参考文献

- 郝晓燕, 刘伟, 李茹, 刘开瑛. 2007. 汉语框架语义知识库及软件描述体系[J]. 中文信息学报, 21(5): 96-100, 138.
- 李济洪. 2010. 汉语框架语义角色的自动标注技术研究[D]. 山西大学博士学位论文, 2010.
- 刘开瑛. 2008. 汉语框架语义网(CFN)构建现状[C]. 第四届全国学生计算语言学研讨会会议论文集. 2008: 1-7.
- 石佼, 李茹, 王智强. 2014. 汉语核心框架语义分析[J]. 中文信息学报, 28(6): 48-55.
- Collin F. Baker, Michael J. Ellsworth, K. Erk. 2007. *SemEval'07 task 19: frame semantic structure extraction*[C]. Proceedings of the 4th International Workshop on Semantic Evaluations. Association for Computational Linguistics, 2007: 99-104.
- Cosmin Adrian Bejan, Chris Hathaway. 2007. *A Pipeline Architecture for Extracting Frame Semantic Structures*[C]. Proceedings of the 4th International Workshop on Semantic Evaluations. Association for Computational Linguistics, 2007: 460-463.
- Dipanjan Das, Desai Chen, André F. T. Martins, etc. 2013. *Frame-semantic parsing*[J]. Computational Linguistics, 2013, 40(1): 9-56.
- Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. 2019. *Bert: Pre-training of deep bidirectional transformers for language understanding*. In NAACL-HLT, pages 4171-4186.
- Charles J. Fillmore. 1982. *Frame semantics*[J]. Linguistics in the morning calm, 1982:111-137.
- Charles J. Fillmore, Collin F. Baker et al. 1998. *The Berkeley FrameNet project*[A]. In: Proceedings of COLING/ACL [C], Montreal, Canada: 1998. 86290.
- Daniel Gildea and Daniel Jurafsky. 2002. *Automatic labeling of semantic roles*. Computational linguistics, 28(3):245-288.
- Yong Guan, Shaoru Guo, Ru Li*, Xiaoli Li, and Hongye Tan. 2021. *Frame Semantic-Enhanced Sentence Modeling for Sentence-level Extractive Text Summarization*[C]. Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing (EMNLP) 2021: 404-4052.
- Yong Guan, Shaoru Guo, Ru Li*, Xiaoli Li, and Hu Zhang. 2021. *Integrating Semantic Scenario and Word Relations for Abstractive Sentence Summarization*[C]. Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing (EMNLP) 2021: 2522-2529.
- Shaoru Guo, Yong Guan, Ru Li*, Xiaoli Li, Hongye Tan. 2020. *Incorporating Syntax and Frame Semantics in Neural Network for Machine Reading Comprehension*[C]. Proceedings of the 28th International Conference on Computational Linguistics (COLING), 2020: 2635-2641.
- Shaoru Guo, Ru Li*, Hongye Tan, Xiaoli Li, Yong Guan. 2020. *A Frame-based Sentence Representation for Machine Reading Comprehension*[C]. Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics (ACL), 2020: 891-896.
- Zhiheng Huang, Wei Xu and Kai Yu. 2015. *Bidirectional LSTM-CRF Models for Sequence Tagging*. arXiv:1508.01991 [cs.CL].
- Takeru Miyato, Andrew M. Dai and Ian Goodfellow. 2016. *Adversarial Training Methods for Semi-Supervised Text Classification*. arXiv:1605.07725 [stat.ML].

- Jianlin Su, Ahmed Murtadha, Shengfeng Pan, Jing Hou, Jun Sun, Wanwei Huang, Bo Wen and Yunfeng Liu. 2022. *Global Pointer: Novel Efficient Span-based Approach for Named Entity Recognition*. arXiv:2208.03054 [cs.CL].
- Jianlin Su, Yu Lu, Shengfeng Pan, Ahmed Murtadha, Bo Wen and Yunfeng Liu. 2022. *RoFormer: Enhanced Transformer with Rotary Position Embedding*. arXiv:2104.09864 [cs.CL].
- Chuhan Wu, Fangzhao Wu, Tao Qi, Yongfeng Huang and Xing Xie. 2022. *NoisyTune: A Little Noise Can Help You Finetune Pretrained Language Models Better*. arXiv:2202.12024 [cs.CL].
- N Xue, M Palmer. 2005. *Automatic semantic role labeling for Chinese verbs*[C]. Proceedings of IJCAI. 2005, 5: 1160-1165.
- Hongyan Zhao, Ru Li*, Xiaoli Li, Hongye Tan. 2021. *CFSRE: Context-aware based on frame-semantics for distantly supervised relation extraction*[J]. Knowledge-Based Systems, 2020, 210: 106480.

作者通讯方式:

- 作者一: 李作恒, 四川省成都市锦江区三色路163号四川久远银海软件股份有限公司, 610023, 18653730429@163.com, 通讯作者;
- 作者二: 郭炫志, 四川省成都市锦江区三色路163号四川久远银海软件股份有限公司, 610023, 494587502@qq.com;
- 作者三: 乔登俭, 四川省成都市锦江区三色路163号四川久远银海软件股份有限公司, 610023, qiaodj@yinhai.com;
- 作者四: 吴 钊, 四川省成都市锦江区三色路163号四川久远银海软件股份有限公司, 610023, fanwu@yinhai.com.