

基于多头自注意力机制和对抗训练的 实体关系联合抽取

甘雨金, 李红军, 唐小川, 王子怡, 甘晨灼, 胡正浩

成都理工大学 计算机与网络安全学院(示范性软件学院), 成都 610059

[摘要] 实体关系联合抽取是构建知识图谱的重要阶段,旨在抽取文本中存在语义关系的实体对。针对已有的实体关系联合抽取方法在抽取过程中存在的冗余关系预测、实体关系重叠以及上下文潜在语义信息捕捉不足的问题,提出联合多头自注意力机制和对抗训练的方法进行实体关系的抽取。该方法利用多头自注意力机制捕获潜在语义特征,以提升模型对上下文语义信息的感知能力;将对抗训练引入模型的训练阶段,以增强模型的泛化能力和鲁棒性。实验结果表明:与现有主流模型对比,提出的模型在 NYT 和 WebNLG 两个公共数据集上都取得了更优的 F1 值,在处理实体关系重叠问题以及不定数量三元组抽取上都能保持稳定的性能表现,验证了模型的有效性。

[关键词] 实体关系联合抽取;对抗训练;多头自注意力;知识图谱

[分类号] TP391.1

[文献标志码] A

Joint extraction of entities and relations based on multi-head self-attention mechanism and adversarial training

GAN Yujin, LI Hongjun, TANG Xiaochuan, WANG Ziyi,

GAN Chenzhuo, HU Zhenghao

College of Computer Science and Cyber Security (Pilot Software College), Chengdu University of Technology, Chengdu 610059, China

Abstract: Extracting entities and relations is an important stage in the construction of the knowledge graph, with the goal of extracting pairs of entities that have semantic relationships with one another from a given text. To solve the problems of redundant relation prediction, overlapping entities and relations, and the inadequate capture of semantic information by prevalent methods for the joint extraction of entities and relations, we propose the fusion of a multi-head self-attention mechanism

[收稿日期] 2023-08-11。

[基金项目] 国家自然科学基金(42050104);自然资源部深时地理环境重建与应用重点实验室开放基金项目(DGERA20221102)。

[第一作者] 甘雨金(1998—),女,硕士研究生,研究方向:自然语言处理,E-mail:2582768962@qq.com。

[通信作者] 李红军(1977—),男,副教授,研究方向:数据挖掘、人工智能,E-mail:lihongjun2012@cdut.edu.cn。

[引用格式] 甘雨金,李红军,唐小川,等,2024.基于多头自注意力机制和对抗训练的实体关系联合抽取[J].成都理工大学学报(自然科学版),51(3):513-521.

Gan Y J, Li H J, Tang X C, et al., 2024. Joint extraction of entities and relations based on multi-head self-attention mechanism and adversarial training[J]. Journal of Chengdu University of Technology (Science & Technology Edition), 51(3):513-521.

with adversarial training in this study to jointly extract entities and relations from texts. The proposed method uses a multi-head self-attention mechanism to capture the potential semantic features of the text and enhance the ability of the model to identify contextual semantic information. Adversarial training is introduced to the training of the model to enhance its robustness and capability for generalization. The results of experiments showed that the proposed model achieved higher values of the $F1$ score than prevalent models in the area on both the NYT and the WebNLG public datasets, and maintained stable performance when dealing with overlapping entities and relations as well as an indefinite number of triple extractions. This verifies the effectiveness of the proposed model.

Key words: joint extraction of entities and relations; adversarial training; multi-head self-attention mechanism; knowledge graph

在自然语言处理中,实体关系抽取是构建大规模知识库及下游任务的基础步骤。目前,实体关系抽取任务依然面临关系重叠问题,如表 1 所示。

其中,Normal 是指句子中的实体对不存在重叠关系;SEO 是指句子中同一个实体和其他实体存在关系;EPO 是指句子中实体对存在不同关系。

表 1 实体关系重叠样例

Table 1 Examples of overlapping entities and relations

重叠样式	文本	三元组
Normal	Jack was born in Hangzhou.	(Jack, birthplace, Hangzhou)
SEO	Susan and Dora live in China.	(Susan, live in, China) (Dora, live in, China)
EPO	Beijing is the capital of China.	(Beijing, capital, China) (Beijing, location, China)

近年来,基于联合抽取(Liang and Du, 2022; Hang et al., 2022; Qiao et al., 2022)的方法被广泛使用。层级指针标注框架 CasRel(Wei et al., 2020)采用共享编码的方式实现实体及关系间的信息交互,首先识别出三元组中的主体,再识别出主体对应的关系及客体。这种方式虽然能够有效解决实体关系重叠的问题,但由于每识别出一个主体后,须与所有关系进行匹配得到客体,因此会产生冗余的关系预测。为了避免该问题,级联双重解码器模型 DualDec(Ma et al., 2021)和潜在关系预测模型 PRGC(Zheng et al., 2021)先抽取关系,后匹配实体,解决了冗余关系预测和关系重叠的问题,但模型对于潜在语义信息的捕捉并不充分。为此,学者们提出融合多头自注意力到实体关系抽取模型中(Liu et al., 2021; Lai et al., 2022; Ji et al., 2024),用于捕获潜在语义信息,但模型的稳定性不强,泛化能力较差。

针对以往实体关系联合抽取方法中存在的不足,本文提出一种将多头自注意力机制和对抗训练相结合的联合抽取模型 MSMAT(multi-head self-attention mechanism and adversarial training)。该模型采用 BERT(Devlin et al., 2019)作

为句子编码器,利用对抗训练添加扰动生成对抗样本,并在解码器中采用多头自注意力机制捕获潜在语义特征,以此提升模型对上下文语义信息的感知能力,再通过潜在关系预测部分和特定关系序列标注部分进行三元组的解码,最后通过全局对应部分进行三元组的正确筛选。实验结果表明,MSMAT 模型能够更好地捕捉文本中的潜在语义信息,有效解决实体关系三元组重叠问题,增强模型间的信息交互,提升模型性能。

1 相关工作

实体关系联合抽取方法主要分为 2 种。第一种是基于管道的抽取方式,先抽取实体,后抽取关系。研究者提出利用卷积神经网络来抽取实体间的关系(Zeng et al., 2014)。Zhang et al. (2015)提出了一种双向长短期记忆网络,使用从词汇资源派生的特征来解决关系抽取问题。然而这 2 个网络都需要依赖额外的词汇资源。基于此,Wang et al. (2016)提出了新的卷积神经网络结构进行关系抽取,该结构利用多个注意力,不借助任何外部信息,通过与任务相关的标记数据进行学习。同样为了不依赖词汇资源的信息,Att-BLSTM

模型融合了注意力机制和双向长短期网络,并使用带有位置标记的原始文本作为输入,使得模型能够获取关键信息(Zhou et al., 2016)。Lee et al. (2019)提出了一种新颖的端到端递归神经网络,该网络结合了实体感知注意力机制和潜在实体类型,在关系分类的通用数据集上表现较好。Wu and He(2019)将目标实体信息和 BERT 语言模型相结合,在抽取了实体的基础上再对关系进行分类。虽然基于管道的方式简化了抽取任务,但是实体识别的错误会导致关系抽取出错,从而造成误差累积问题。

基于此,学者们提出了另一种对实体和关系进行联合抽取的方式,利用共享序列编码层实现信息的交互。根据解码器的不同,将联合抽取的方法分为 2 种:一种是基于联合解码的抽取;另一种是基于参数共享的联合抽取(张少伟等,2022)。

基于联合解码的抽取方法,在共享序列编码层信息后,添加统一的解码器,直接得到实体关系三元组。CopyRE 模型基于序列到序列学习方式进行端到端训练,以解决实体间关系的重叠问题(Zeng et al., 2018)。基于此模型,考虑到三元组的提取顺序,OrderCopyRE 模型将强化学习应用于序列到序列的实体关系联合抽取中,能够自由的生成三元组(Zeng et al., 2019)。

基于参数共享的联合抽取方法,在实体识别和关系抽取时分别解码,通过共享序列编码层信息实现 2 个子任务间信息的交互。GraphRel 模型基于图卷积网络进行联合提取,为每个实体对进行关系匹配以解决关系重叠问题,但造成了冗

余的关系预测(Fu et al., 2019)。SPE 模型为了避免序列到序列模型需要固定关系三元组的顺序问题,将实体关系联合抽取看作是集合预测问题,能够生成和顺序无关的三元组(Sui et al., 2020)。TPLinker 模型作为一个单阶段联合提取模型,引入了一种新颖的握手标记策略,解决了曝光偏差的问题,但该模型的抽取效率较低(Wang et al., 2020)。SMHSA 模型(Liu et al., 2021)和 RMAN 模型(Lai et al., 2022)将多头自注意力层分别作用于实体关系联合抽取中的关系检测和句子的表示,捕获了句子间潜在的语义信息,但模型不稳定,泛化能力较差。

此外,对抗训练作为一种正则化方法,通过在模型训练时添加扰动样本能有效提升模型的鲁棒性和泛化能力。Goodfellow et al. (2015)首次提出将对抗训练用于图像领域,提升了模型识别原始图片的准确率及模型的鲁棒性。在 NLP 领域, Miyato et al. (2016)通过在词嵌入上添加扰动的方式将对抗训练方法用于半监督的文本分类。而 Bekoulis et al. (2018)将对抗训练用于多上下文实体关系联合抽取,证明了对抗训练能够有效提升模型的性能,但该模型使用双向长短期记忆网络编码句子,语义特征提取能力较低。Zhu et al. (2020)还将对抗训练扩展到了自然语言理解任务中。

2 MSMAT 模型

MSMAT 模型(图 1)包括 3 个部分:BERT 预训练模块、生成实体关系三元组的解码器模块以及增强模型鲁棒性的对抗训练模块。其中,解

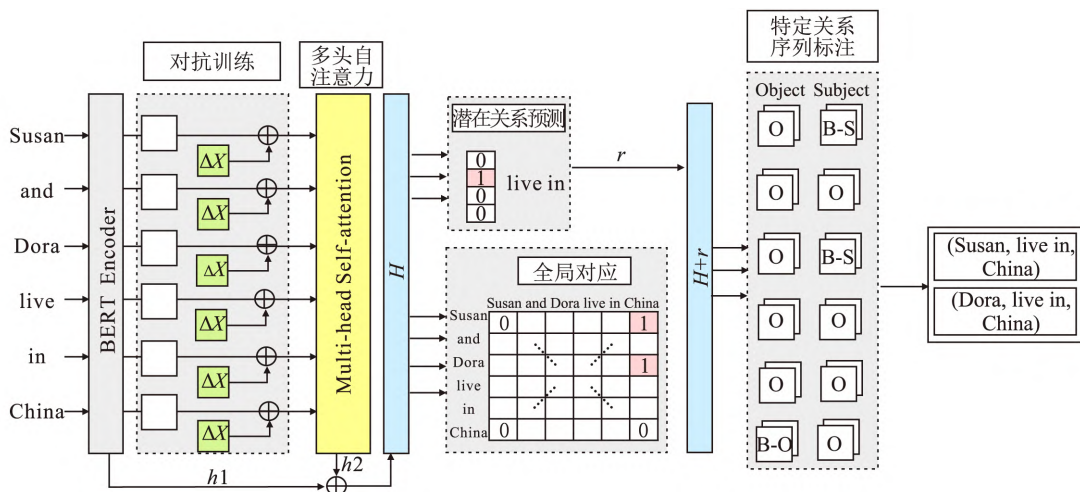


图 1 基于多头自注意力和对抗训练的实体关系抽取模型
Fig. 1 Model of entity and relation extraction based on multi-head self-attention and adversarial training

码器由 4 个部分组成:多头自注意力机制模块用于获取重要的潜在语义信息;潜在关系预测模块得到输入句子存在的潜在关系;特定关系序列标注模块的作用是先预测的关系表示和句子的信息表示结合,再进行序列标注生成头尾实体;全局对应模块用于生成头尾实体的位置关联矩阵,并对正确的三元组进行筛选。

2.1 编码器

BERT 预训练模块用于获取句子间上下文语义信息。对于数据集中的文本,传入 BERT 中可将句子转化为矩阵向量。BERT 的输入向量包含词嵌入和位置嵌入 2 个部分。假设输入长度为 n 的序列 $S = \{w_1, w_2, \dots, w_n\}$, 其中 w_t 表示句子中的第 t 个字,通过多层双向 Transformer 进行编码,可得到蕴含语义信息的序列矩阵向量。

2.2 解码器

2.2.1 多头自注意力机制模块

多头自注意力机制通过多个并行的自注意力层来捕捉序列中的不同级别信息,每个自注意力层关注不同的局部信息,再将这些信息融合以获得更全面的信息,从而提升模型的表达能力。假设多头自注意力模块的输入向量为 h_1 ,通过公式(1)~(3)对输入向量分别进行 3 次线性变换得到查询矩阵 Q_i 、键矩阵 K_i 、值矩阵 V_i ,再利用公式(4)缩放点积的方法计算出单个的自注意力机制获取的潜在信息矩阵,最后通过公式(5)将多个自注意力机制形成的信息矩阵进行线性变换后得到输入向量的完整语义信息。计算过程如下:

$$Q_i = W_{q(i)} \cdot h_1 \quad (1)$$

$$K_i = W_{k(i)} \cdot h_1 \quad (2)$$

$$V_i = W_{v(i)} \cdot h_1 \quad (3)$$

$$head_i = \text{softmax}\left(\frac{Q_i \cdot K_i^T}{\sqrt{d_k}}\right) \cdot V_i \quad (4)$$

$$h_2 = [head_1; head_2; \dots; head_n]W_o \quad (5)$$

其中, $W_{q(i)} \in R^{d \times d_k}$, $W_{k(i)} \in R^{d \times d_k}$, $W_{v(i)} \in R^{d \times d_v}$, $W_o \in R^{nd_v \times d}$ 都是可训练的参数矩阵; d, d_k, d_v 分别代表输入矩阵、键矩阵和值矩阵的维度; $i=1, 2, \dots, n$ 代表多头自注意力的头数目; $\sqrt{d_k}$ 是缩放因子。

2.2.2 潜在关系预测模块

为了避免实体间冗余的关系预测,先进行潜在的关系预测。如果预测概率超过某个阈值 λ_1 , 则相应的关系被标记为 1, 否则标记为 0, 如图 1

中潜在关系预测所示。假设给定的句子序列有 n 个 token, 将句子经过编码器和多头自注意力机制处理后捕获到的完整句子语义信息向量分别为 h_1 和 h_2 , 再把这 2 个向量联合表示为向量 $H = [h_1; h_2]$, $[. ; .]$ 表示向量的拼接操作, 对于潜在关系的预测计算过程如下:

$$h^{avg} = \text{Avgpool}(H) \quad (6)$$

$$P_{rel} = \sigma(W \cdot h^{avg} + b) \quad (7)$$

式中: $\text{Avgpool}()$ 是平均池化操作; $h^{avg} \in R^{d \times 1}$ 是通过平均池化操作获取的特征向量; $W \in R^{d \times 1}$ 是可训练权重; b 是偏置; σ 是 sigmoid 激活函数。

2.2.3 特定关系序列标注模块

在通过潜在关系预测模块后, 将预测的关系作为额外的特征进行头尾实体的获取, 为了解决头尾实体的重叠问题, 采用 2 个 BIO 序列标注的方式去抽取头尾实体, 如图 1 中特定关系序列标注所示。此模块的操作过程如下:

$$P_{i,j}^s = \text{softmax}[W_s(h_i + u_j)b_s] \quad (8)$$

$$P_{i,j}^o = \text{softmax}[W_o(h_i + u_j) + b_o] \quad (9)$$

在此, $h_i \in R^{d \times 1}$ 是通过编码器和多头自注意力模块处理后的第 i 个 token 的输出, 若设 $U \in R^{d \times n_r}$ 表示可训练关系嵌入矩阵, 其中, n_r 表示预测的关系集合, $u_j \in R^{d \times 1}$ 则是第 j 个关系的嵌入表示, $W_s, W_o \in R^{d \times 3}$ 分别是为了获取头实体和尾实体对应的可训练权重, b_s 和 b_o 是对应的偏置, 标注集合 {B, I, O} 的大小为 3。

2.2.4 全局对应模块

经过特定关系序列标注模块后, 可得到输入句子的所有潜在关系对应的头尾实体构成的三元组, 为了避免生成无效的三元组, 利用全局对应模块进行三元组的筛选。首先, 本模型会枚举所有可能的头实体和尾实体并将他们配对; 然后, 会检查每一对头尾实体在全局对应矩阵中的对应分值, 如果分值超过某个阈值 λ_2 , 则保留该头尾实体对, 否则将其过滤。由于该模块的生成只依赖于编码器和多头自注意力模块的联合输出, 所以该模块和潜在关系模块是同时学习得到的, 如图 1 中的全局对应所示。假设该模块生成的全局矩阵为 M , 给定输入序列 S 有 n 个 token, 则该全局对应矩阵的形状为 $R^{n \times n}$, 在矩阵中的每个元素值的获取方式为:

$$P_{i_s, i_o} = \sigma(W[h_i^s; h_j^o] + b) \quad (10)$$

式中: $h_i^s, h_j^o \in R^{d \times 1}$ 是关于输入句子中第 i 个 to-

ken 和第 j 个 token 在通过编码器和多头自注意力模块处理后的向量表示,用来形成潜在的头尾实体对; $W \in R^{2d \times 1}$ 是一个可训练权重; σ 是 sigmoid 函数。

2.3 训练策略

2.3.1 对抗训练

为了提高 MSMAT 模型的稳定性和泛化能力,在模型的训练阶段加入对抗训练。如图 1 对抗训练部分所示,在 MSMAT 模型中,假设经过 BERT 编码后得到的嵌入向量为 x ,通过对 x 添加对抗扰动 Δx ,最后得到对抗嵌入向量 x_{adv} ,计算公式如下:

$$g = \nabla_x L(x, y; \theta) \quad (11)$$

$$\Delta x = \epsilon \cdot \frac{g}{\|g\|_2} \quad (12)$$

$$x_{adv} = x + \Delta x \quad (13)$$

式中: g 为损失函数 $L(x, y; \theta)$ 对输入向量 x 求导得到的梯度; ϵ 为表示扰动程度的超参数,默认取值为 1。

2.3.2 目标函数

MSMAT 模型的整体损失值由潜在关系预测模块、特定关系序列标注以及全局对应模块 3 部分损失之和组成。潜在关系预测模块和全局对应模块采用二元交叉熵损失函数,特定关系序列标注采用多元交叉熵损失函数,各部分的损失函数计算过程如下:

$$L_{rel} = -\frac{1}{n_r} \sum_{i=1}^{n_r} [y_i \log P_{rel} + (1 - y_i) \log(1 - P_{rel})] \quad (14)$$

$$L_{seq} = -\frac{1}{2 \times n \times n_r^{pot}} \sum_{t=\{s,o\}} \sum_{j=1}^{n_r^{pot}} \sum_{i=1}^n y_{i,j}^a \log P_{i,j}^a \quad (15)$$

表 3 测试集中实体重叠类型以及三元组数目统计信息

Table 3 Types of entity overlaps and the number of triples in the test set

数据集	Normal	SEO	EPO	N=1	N=2	N=3	N=4	N≥5
NYT	3071	1273	1168	3089	1137	300	317	157
WebNLG	239	448	6	256	175	138	93	41

3.2 评价指标

本文采用准确率 P 、召回率 R 和 $F1$ 值作为评价指标对模型是否正确抽取三元组进行评估,指标如下:

$$F1 = \frac{2 \times P \times R}{P + R} \times 100\% \quad (18)$$

$$L_{global} = -\frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n [y_{i,j} \log P_{i_s, j_o} + (1 - y_{i,j}) \log(1 - P_{i_s, j_o})] \quad (16)$$

式中: n_r 是所有关系集合的大小; y_i 是第 i 个关系类别的真实标记; n 是输入序列的长度; n_r^{pot} 是预测的输入语句中潜在的关系集合大小; $y_{i,j}^a$ 是在输入长度为 i 的序列中,被标注为头实体和尾实体对应的第 j 个关系类别的真实标记向量; $y_{i,j}$ 是全局对应矩阵中第 i 行,第 j 列个元素对应的真实标记。模型总的联合损失为三部分损失的总和,如公式(17)所示。

$$L_{total} = L_{rel} + L_{seq} + L_{global} \quad (17)$$

3 实验与结果

3.1 数据集

本文使用 2 个公共的实体关系联合抽取数据集 WebNLG (Gardent et al., 2017) 和 NYT (Riedel et al., 2010) 验证 MSMAT 模型的有效性。WebNLG 数据来源于 DBpedia (Auer et al., 2007), NYT 数据来源于纽约时报。本文对 2 个数据集的划分与文献 (Zheng et al., 2021) 一致,训练集、验证集和测试集划分比例约为 8:1:1,具体的数据集信息如表 2 所示,根据数据集中实体关系重叠的不同情况以及输入语句中不同三元组的数目情况对测试数据集进行划分,如表 3 所示。

表 2 数据集统计信息

Table 2 Statistical information on the dataset

数据集	训练集	验证集	测试集	关系数
NYT	56196	5000	5000	24
WebNLG	5019	500	703	216

式中: P 表示模型做出正确预测的数量占总体预测为正确数量的百分比; R 表示模型做出正确预测的数量占实际预测正确数量的百分比; $F1$ 为 P 和 R 的调和平均值。

3.3 实验设置

MSMAT 模型运行显卡为 RTX 3080,显存

10 GB, 处理器为 15 核 Intel Xeon Platinum 8358P CPU@2.60 GHz, 运行内存为 80 GB。深度学习模型的搭建采用 PyTorch1.6, BERT 作为预训练模型使用 12 层 Transformer, 其中词向量设为 768 维, 在训练过程中采用 Adam 优化器, 学习率设置为 1×10^{-5} 来进行梯度下降和反向传播, 句子最大长度设为 100, 训练轮次为 50。对于 NYT 和 WebNLG, 其 batch size 分别设为 18 和 6, 多头自注意力头数设为 8, 潜在关系预测模块中关系阈值 λ_1 设置为 0.1, 全局对应模块中特定的阈值 λ_2 设置为 0.5。

3.4 实验结果及分析

3.4.1 MSMAT 与现有方法有效性的比较

本文将提出的模型和以下基线模型进行比较, 以验证所提模型的有效性。

GraphRel(Fu et al., 2019): 该模型利用图卷积网络(GCN)为每一个关系建立完整的关系图, 然后再整合关系图上的实体对。

OrderCopyRE(Zeng et al., 2019): 该模型考虑到三元组的提取顺序, 将强化学习应用于序列到序列的实体关系联合抽取模型中。

CasRel(Wei et al., 2020): 该模型采用级联二进制框架, 先抽取头实体, 然后在此基础上抽取关系以及对应的尾实体。

SPE(Sui et al., 2020): 该模型提出集合预测网络进行实体关系联合抽取, 避免考虑三元组的顺序问题。

DualDec(Ma et al., 2021): 该模型基于 CasRel 模型, 提出双解码器方法来解决重叠的关系三元组问题。

PRGC(Zheng et al., 2021): 该模型先抽取关系, 再将关系视为潜在特征去进行实体的抽取, 最后利用全局对应组件去对齐头尾实体。

基于数据集 NYT 和 WebNLG 在同一系统配置下运行所有基线模型和本模型得到的实验结果如表 4 所示。从表 4 中可以看出, 本文所提的方法在 2 个数据集中都取得了较基线模型更好的结果。在 NYT 数据集中, 本文的 F1 值相较于最好的基线模型 DualDec 高出 0.4%, 相较于基准模型 PRGC 高出 0.9%, 说明本文的方法比基线模型更稳定, 性能表现更好。对于 WebNLG 数据集, 本文的方法获得了最高 F1 值, 相较于基准模型 PRGC 高出了 0.7%, 比经典的 CasRel 模型高出

2.2%。通过对比实验表明, 本文所提 MSMAT 模型的泛化能力较基线模型更好, 能有效地提升实体关系联合抽取性能。

表 4 不同方法在 NYT 和 WebNLG 数据集上的实验结果

Table 4 Results obtained by different methods on the NYT and WebNLG datasets

方法	NYT/%			WebNLG/%		
	P	R	F1	P	R	F1
GraphRel	63.9	60.0	61.9	44.7	41.1	42.9
OrderCopyRE	77.9	67.2	72.1	63.3	59.9	61.6
CasRel	89.1	89.4	89.2	87.7	85.0	86.3
SPE	83.3	84.2	83.7	83.9	82.2	83.0
DualDec	90.5	91.4	90.9	86.2	83.7	84.9
PRGC	91.1	89.6	90.4	89.1	86.6	87.8
MSMAT	91.9	90.7	91.3	90.2	86.9	88.5

3.4.2 MSMAT 对实体关系重叠的影响

为了探寻本文所提模型在实体关系重叠问题下提取三元组的性能表现, 与部分基线模型对比得到了实验结果(图 2)。从整体上看, 本文的模型在 2 个数据集的 Normal, SEO, EPO 三种情况下都取得了最好的 F1 值。对于 NYT 和 WebNLG 数据集来说, 在 Normal 情况下, 相较于目前最优的 PRGC 模型本文所提模型的性能增量分别为 1.7% 和 3.8%。在 SEO 和 EPO 对应的关系重叠模式下, MSMAT 在 NYT 数据集中相较于基线模型都有所提升。在 WebNLG 数据集中, 对于 SEO 的情况, MSMAT 性能略高于基线模型, 而对于 EPO 的情况, 本文模型的性能明显高于其他的基线模型。由此可知, 在处理实体关系重叠问题时, MSMAT 能更精确地提取三元组, 从而产生更好的性能增益。

3.4.3 MSMAT 对提取三元组数目的影响

为了进一步验证本模型对输入的文本中存在的不定量三元组数目的抽取能力, 将 NYT 和 WebNLG 测试数据集划分为 5 种类型, 分别代表着不同的三元组数目, 将本模型和部分基线模型对比获得了实验结果(图 3)。随着三元组数量的增加, MSMAT 模型相较于所有基线模型在 F1 值上都取得极具竞争力的结果。特别对于 $N \geq 5$ 时, MSMAT 在 NYT 和 WebNLG 数据集上的 F1 值达到了 89.8% 和 85.4%, 相较于 PRGC 提升了 0.1% 和 2%, 这是因为本文模型引入的多头自注意力能捕捉文本中蕴含的潜在语义特征, 可

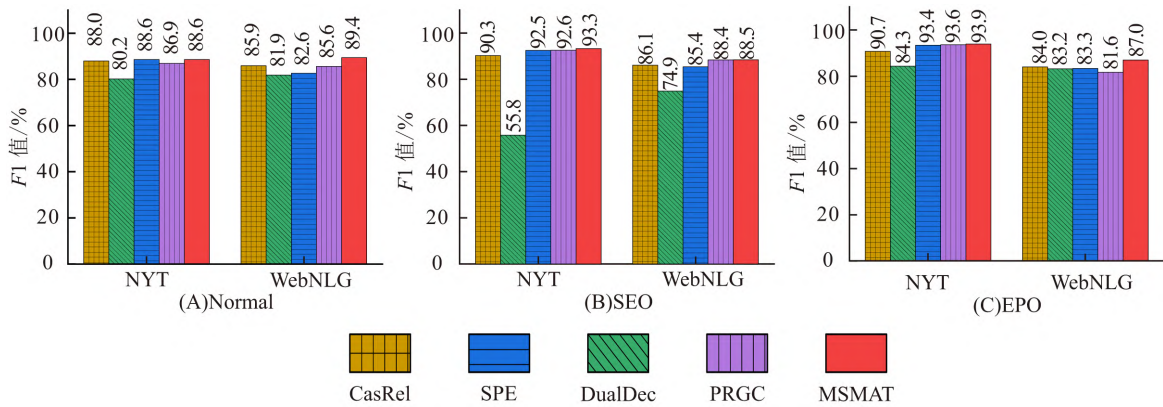


图 2 从不同关系重叠样式抽取三元组的实验结果

Fig. 2 Results of extracting triples from different patterns of overlapping relations

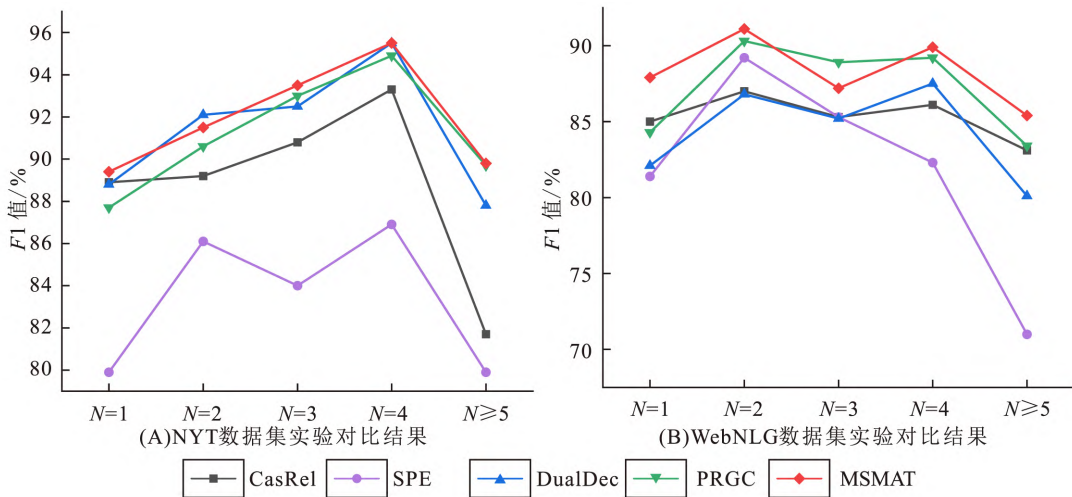


图 3 抽取不同三元组数目的实验结果

Fig. 3 Results of extracting different numbers of triples

以更好地获取句子中的关键信息。同时,在模型对于复杂的场景处理时,对抗训练的加入可以提升模型的鲁棒性,增强模型的性能表现。总的来说,MSMAT 模型能更好地处理复杂的三元组数量抽取场景。

3.4.4 消融实验

为了探究本文添加的多头自注意力和对抗训练对 MSMAT 性能的影响,本文在 WebNLG 上进行消融实验,实验结果如表 5 所示,其中, w/o Att 和 w/o AD 分别表示去除多头自注意力模块和对抗训练模块。

对表 5 的实验结果分析可知,MSMAT 模型在仅添加了多头自注意力模块时,在 WebNLG 数据集上的准确率 P 、召回率 R 和 $F1$ 值分别提升了 1.2%,1%,1%,这表明了多头自注意力模

块的添加能够进一步融合潜在的语义特征信息,从而提升模型的性能表现。在引入对抗训练模块时,模型在 WebNLG 数据集上的准确率 P 、召回率 R 和 $F1$ 值分别提高了 0.8%,0.3%,0.5%,说明对抗样本能有效地提升模型的鲁棒性,使模型具有更好的泛化能力,从而能更完整且准确地抽取三元组,表明了添加多头自注意力模块和对抗训练模块的有效性。

表 5 MSMAT 在 WebNLG 数据集上的消融实验结果
Table 5 Results of ablation experiments on MSMAT using the WebNLG dataset

方法	$P/\%$	$R/\%$	$F1/\%$
MSMAT	90.2	86.9	88.5
w/o Att	89.4	86.6	88.0
w/o AD	89.0	85.9	87.5

4 总结

在实体关系联合抽取任务中,实体关系间语义信息的捕捉和联合抽取模型的稳定性,对于实体关系三元组抽取任务的最终性能有着重要的影响,对于知识图谱的构建也至关重要。针对现有实体关系联合抽取方法中存在的不足,本文提出一种将多头自注意力机制和对抗训练相结合的联合抽取方法,实验结果表明,本文提出的模型:

a. 结合多头自注意力机制和对抗训练,在捕获更深层次的潜在语义特征的同时,还增强了模型的泛化能力。

b. 在 2 个公共数据集上获得了更好的结果,在处理实体关系重叠及复杂的三元组抽取场景也有较好的性能表现,验证了模型的有效性。

在未来的工作中,可将该方法用于特定领域实体关系三元组的抽取任务,为知识图谱的构建奠定基础。

[参 考 文 献]

张少伟,王鑫,陈子睿,等,2022. 有监督实体关系联合抽取方法研究综述[J]. 计算机科学与探索,16(4):713-733.

Zhang S W, Wang X, Chen Z R, *et al.*, 2022. Survey of supervised joint entity relation extraction methods[J]. Journal of Frontiers of Computer Science and Technology, 16(4): 713-733. (in Chinese)

Auer S, Bizer C, Kobilarov G, *et al.*, 2007. DBpedia: A nucleus for a web of open data[C]//Proceedings of the 6th International Semantic Web Conference. Berlin: Springer; 722-735.

Bekoulis I, Deleu J, Demeester T, *et al.*, 2018. Adversarial training for multi-context joint entity and relation extraction[C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: Association for Computational Linguistics; 2830-2836.

Devlin J, Chang M W, Lee K, *et al.*, 2019. 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. Stroudsburg: Association for Computational Linguistics; 4171-4186.

Fu T J, Li P H, Ma W Y, 2019. GraphRel: Modeling text

as relational graphs for joint entity and relation extraction[C]//Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. Stroudsburg: Association for Computational Linguistics; 1409-1418.

Gardent C, Shimorina A, Narayan S, *et al.*, 2017. Creating training corpora for NLG micro-planners[C]// Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics. Stroudsburg: Association for Computational Linguistics; 179-188.

Goodfellow I J, Shlens J, Szegedy C, 2015. Explaining and harnessing adversarial examples[C]//Proceedings of the 3rd International Conference on Learning Representations. Ithaca: OpenReview. net; 1-11.

Hang T T, Feng J, Yan L, *et al.*, 2022. Joint extraction of entities and relations using multi-label tagging and relational alignment[J]. Neural Computing and Applications, 34(8): 6397-6412.

Ji B, Li S S, Xu H, *et al.*, 2024. Span-based joint entity and relation extraction augmented with sequence tagging mechanism[J]. Science China (Information Sciences), 67(5): 152105.

Lai T Q, Cheng L L, Wang D P, *et al.*, 2022. RMAN: Relational multi-head attention neural network for joint extraction of entities and relations[J]. Applied Intelligence, 52(3): 3132-3142.

Lee J, Seo S, Choi Y S, 2019. Semantic relation classification via bidirectional LSTM networks with entity-aware attention using latent entity typing[J]. Symmetry, 11(6): 785.

Liang Z Y, Du J P, 2022. Sequence to sequence learning for joint extraction of entities and relations[J]. Neurocomputing, 501: 480-488.

Liu J, Chen S W, Wang B Q, *et al.*, 2021. Attention as relation: Learning supervised multi-head self-attention for relation extraction [C/OL]//Proceedings of the Twenty-ninth International Conference on International Joint Conferences on Artificial Intelligence, 524 [2024-04-18]. <https://doi.org/10.24963/ijcai.2020/524>.

Ma L B, Ren H M, Zhang X L, 2021. Effective cascade dual-decoder model for joint entity and relation extraction[EB/OL]. (2021-06-27) [2024-04-22]. <https://doi.org/10.48550/arXiv.2106.14163>.

Miyato T, Dai A M, Goodfellow I, 2016. Adversarial training methods for semi-supervised text classification [C]//Proceedings of the 5th International Conference

- on Learning Representations. Ithaca; OpenReview.net;2763–2774.
- Qiao B,Zou Z Y,Huang Y,*et al.*,2022. A joint model for entity and relation extraction based on BERT[J]. *Neural Computing and Applications*,34:3471–3481.
- Riedel S,Yao L M,McCallum A,2010. Modeling relations and their mentions without labeled text[C]//Proceedings of the 2010 European Conference on Machine Learning and Knowledge Discovery in Databases. Berlin;Springer;148–163.
- Sui D B,Zeng X R,Chen Y B,*et al.*,2023. Joint entity and relation extraction with set prediction networks[J]. *IEEE transactions on neural networks and learning systems*;37067968.
- Wang L L,Cao Z,De Melo G,*et al.*,2016. Relation classification via multi-level attention CNNs[C]//Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics. Stroudsburg; Association for Computational Linguistics;1298–1307.
- Wang Y C,Yu B W,Zhang Y Y,*et al.*,2020. TPLinker; Single-stage joint extraction of entities and relations through token pair linking[C]//Proceedings of the 28th International Conference on Computational Linguistics. Barcelona;International Committee on Computational Linguistics;1572–1582.
- Wei Z P,Su J L,Wang Y,*et al.*,2020. A novel cascade binary tagging framework for relational triple extraction[C]//Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. Stroudsburg; Association for Computational Linguistics;1476–1488.
- Wu S C,He Y F,2019. Enriching pre-trained language model with entity information for relation classification[C]//Proceedings of the 28th ACM International Conference on Information and Knowledge Management. New York; Association for Computing Machinery;2361–2364.
- Zeng D J,Liu K,Lai S W,*et al.*,2014. Relation classification via convolutional deep neural network[C]//Proceedings of COLING 2014, the 25th International Conference on Computational Linguistics; Technical Papers. Dublin; Association for Computational Linguistics;2335–2344.
- Zeng X R,He S Z,Zeng D J,*et al.*,2019. Learning the extraction order of multiple relational facts in a sentence with reinforcement learning[C]//Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP). Stroudsburg; Association for Computational Linguistics;367–377.
- Zeng X R,Zeng D J,He S Z,*et al.*,2018. Extracting relational facts by an end-to-end neural model with copy mechanism[C]//Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics. Stroudsburg; Association for Computational Linguistics;506–510.
- Zhang S,Zheng D Q,Hu X C,*et al.*,2015. Bidirectional long short-term memory networks for relation classification[C]//Proceedings of the 29th Pacific Asia Conference on Language, Information and Computation. Shanghai; Shanghai Jiaotong University; 73–78.
- Zheng H Y,Wen R,Chen X,*et al.*,2021. PRGC; Potential relation and global correspondence based joint relational triple extraction[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. Boston; Association for Computational Linguistics;6225–6235.
- Zhou P,Shi W,Tian J,*et al.*,2016. Attention-based bidirectional long short-term memory networks for relation classification[C]//Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics. Stroudsburg; Association for Computational Linguistics;207–212.
- Zhu C,Cheng Y,Gan Z,*et al.*,2020. FreeLB; Enhanced adversarial training for natural language understanding[C]//Proceedings of the 8th International Conference on Learning Representations. Ithaca; OpenReview.net;11232–11245.

(责任编辑:黄维婷)