

# 基于动态关系原型的持续关系抽取技术

钟 将<sup>1,2</sup>, 戴启祝<sup>1,2</sup>, 李 雪<sup>3</sup>

(1. 重庆大学计算机学院, 重庆 400044; 2. 重庆大学信息物理社会可信服务计算(CPS)教育部重点实验室, 重庆 400044;  
3. 昆士兰大学电气工程和计算机科学学院, 布里斯班 4072)

**摘要:** 持续关系抽取(Continuous Relation Extraction, CRE)在理解和适应不断变化的数据环境中扮演着至关重要的角色。传统的CRE技术通常面临两大难题:一是关系模式的持续演变,二是遗忘之前学习的关系的风险。尽管存储和重放旧关系典型示例的做法在减少遗忘方面已被证明是有效的,但反复重放这些固定且有限的样本可能导致过拟合。为了解决这一问题,本文提出了一种基于动态原型的持续关系抽取方法。该方法结合了密度聚类和生成式大型语言模型,以应对上述挑战,本文将命名为密度聚类和生成式大型语言建模(Continuous Relation Extraction with Density based Clustering and Generative Large Language Model, CRE-DCGLLM)。具体而言,本文采用了密度聚类技术来提取记忆样本,缓解对先前任务的遗忘问题,并基于全量样本和记忆样本设计了动态关系原型。此外,本文通过生成式大语言模型为记忆样本生成伪样本用于重放训练,以解决因多次重放导致的模型过拟合问题。同时,本文还运用焦点知识蒸馏技术,以提升对变化中关系模式的适应性能。通过在FewRel数据集和TACRED数据集上进行的一系列实验,本文验证了该方法的有效性。实验结果显示,本文的方法在持续关系抽取的准确性和效率方面都取得了显著提升,特别是在处理相似关系、防止知识遗忘以及克服过拟合等方面表现出了卓越的性能。

**关键词:** 持续关系抽取;聚类;大语言模型;密度峰值;动态原型

**基金项目:** 国家自然科学基金(No.62176029)

**中图分类号:** TP3;TP301.6

**文献标识码:** A

**文章编号:** 0372-2112(2025)09-3287-12

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.12263/DZXB.20240472

## Continuous Relation Extraction Technique Based on Dynamic Relational Prototypes

ZHONG Jiang<sup>1,2</sup>, DAI Qi-zhu<sup>1,2</sup>, LI Xue<sup>3</sup>

(1. School of Computer Science, Chongqing University, Chongqing 400044, China;

2. Key Laboratory of Dependable Service Computing in Cyber Physical Society, Chongqing University, Chongqing 400044, China;

3. School of Electrical Engineering and Computer Science, The University of Queensland, Brisbane 4072, Australia)

**Abstract:** Continuous relation extraction (CRE) plays a crucial role in understanding and adapting to the ever-changing data environment. Traditional CRE techniques often face two major challenges: the continuous evolution of relationship patterns and the risk of forgetting previously learned relationships. Although storing and replaying typical examples of old relationships has been proven effective in reducing forgetting, repeatedly replaying these fixed and limited samples can lead to overfitting. To address this issue, this paper proposes a dynamic prototype-based continuous relation extraction method that combines density clustering and generative large language models to tackle the aforementioned challenges, which is named a dynamic prototype-based continuous relation extraction method (Continuous Relation Extraction with Density based Clustering and Generative Large Language Model, CRE-DC GLLM) in this paper. Specifically, this paper employs density clustering technology to extract memory samples to alleviate the problem of forgetting previous tasks, and designs dynamic relationship prototypes based on full samples and memory samples. In addition, this paper uses a generative large model to generate pseudo-samples for memory samples for replay training, to solve the problem of model overfitting caused by multiple replays. At the same time, this paper also uses focused knowledge distillation technology to enhance the adaptability to changing relationship patterns. A series of experiments conducted on the FewRel dataset and the TACRED dataset

have verified the effectiveness of this method. The experimental results show that this method has achieved significant improvements in the accuracy and efficiency of continuous relation extraction, especially in handling similar relationships, preventing knowledge forgetting, and overcoming overfitting, it has shown excellent performance.

**Key words:** continuous relation extraction; clustering; large language model; density peaks; dynamic prototype

**Foundation Item(s):** National Natural Science Foundation of China (No.62176029)

## 1 引言

关系抽取 (Relation Extraction, RE)<sup>[1,2]</sup> 是自然语言处理 (Natural Language Processing, NLP) 和数据分析领域的一个重要组成部分, 其重点是识别和归类文本中实体之间的语义关系. 在各种应用中, 从信息检索和知识库到情感分析和生物医学数据解读, 这一过程对于理解语言的结构和含义至关重要. 传统的 RE 模型, 如 Zhou 等人<sup>[3]</sup> 和 Baldini Soares 等人<sup>[4]</sup> 的研究所, 通常在静态框架内采用固定的方法, 处理一组预定义的关系. 随着数据流的不断发展, 有效的持续关系抽取 (Continuous Relation Extraction, CRE) 变得越来越重要. 这一过程必须适应新的关系模式和类型, 同时保留以前学习到的信息. 然而, 传统的关系提取方法在动态环境中往往不尽如人意. 它们通常依赖于静态数据集, 而静态数据集可能无法代表真实世界数据的全部复杂性或不断变化的性质. 此外, 这些方法还可能存在灾难性遗忘的问题, 即学习新任务可能会导致丢失以前获得的知识. 此外, 区分相似或类似关系的独特挑战也给任务增加了另一层复杂性.

最近, 一些研究人员在持续关系抽取 (CRE) 领域做出了贡献<sup>[5-8]</sup>. CRE 旨在在适应性保留先前学习任务的同时整合新任务, 其面临的一个挑战性问题灾难性遗忘<sup>[9]</sup>, 这是一种学习新任务会损害先前学习任务表现的现象. 为了缓解这个问题, 已经探索了各种策略, 从基于正则化的方法<sup>[10,11]</sup> 和动态架构方法<sup>[12,13]</sup> 到基于记忆的方法<sup>[5,14]</sup>.

当前的持续关系抽取模型主要关注于基于记忆的方法, 该方法依赖存储和重放有限数量记忆样本, 它们面临记忆样本的有偏表示和过拟合问题<sup>[15,16]</sup>. 如图 1 所示, 与重放前相比, 重复重放后的记忆样本的表示被扭曲, 选择和使用记忆样本的过程往往忽略了它们的连续表示和多样性, 导致模型性能下降<sup>[6,17,18]</sup>.

在经验性研究中发现, 对有限的固定记忆样本使用对比学习进行重复的重放训练, 会导致这些样本之间的余弦相似度变得很高, 这导致它们失去了原有的多样性和代表性. 图 1 展示了记忆样本的余弦相似度热图的可视化 (横纵坐标均为记忆样本). 图 1(a) 反映了四种方法, 即 EMAR<sup>[6]</sup> (continual relation learning via Episodic Memory Activation and Reconsolidation)、RP-CRE<sup>[8]</sup>

(refining sample embeddings with Relation Prototypes to enhance Continual Relation Extraction)、CRL<sup>[18]</sup> (Consistent Representation Learning for continual relation extraction) 和 CRECL<sup>[17]</sup> (Continual Relation Extraction framework with Contrastive Learning) 在初始  $K$  均值下记忆样本的相似性. 图 1(b) 显示了使用 CRECL 模型进行三次重放后记忆样本的相似性. 实证分析显示, 当本文重复重放一小组固定的记忆样本时, 它们之间的相似性增加. 因此, 在多次重放后, 记忆样本的扭曲严重, CRE 中的过拟合问题变得越来越明显. 在本文的比较分析之后, 记忆样本扭曲有两个原因: 一个是在初始训练结束时选择了非常相似的文本; 第二个是在持续训练阶段, 样本的重复重放导致了模型对样本表示的偏差.

为了解决上述问题, 本文引入了一种新颖的持续关系抽取方法, 通过整合密度聚类 and 生成式大型语言建模 (Continuous Relation Extraction with Density based Clustering and Generative Large Language Model, CRE-DCGLLM) 来应对这些挑战. 通过应用密度峰值聚类并设计动态关系原型来减轻对旧任务的灾难性遗忘. 然后, 本文通过生成式大型语言模型生成伪样本, 防止了记忆样本因多次重放训练而导致的过拟合问题. 在这里, 本文采用 Qwen<sup>[19]</sup> 模型来生成伪样本. 最后还利用焦点知识蒸馏 (Focal Loss Distillation, FLD) 来提高不断演变的关系模型的性能. 图 1(c) 展示了生成式大模型增强和密度聚类下的记忆样本的相似性.

本文的主要贡献可以概括如下:

(1) 通过认识到  $K$ -均值算法在选择样本方面的不足, 采用密度峰值聚类来选择代表性样本, 并通过设计动态关系原型来消除 CRE 旧任务的记忆灾难性遗忘问题.

(2) 为了解决模型过拟合导致的记忆样本表示偏差问题, 本文提出了通过生成式大型语言模型生成伪样本数据的记忆增强方法. 这种方法减少了模型的过拟合. 此外, 由于大模型生成的伪样本并未参与后续的原型计算, 确保了记忆中样本数据的纯净性.

(3) 在两个基准数据集 (FewRel 数据集和 TACRED 数据集) 上的实验结果表明, 本文的模型在性能上超越了基准模型.

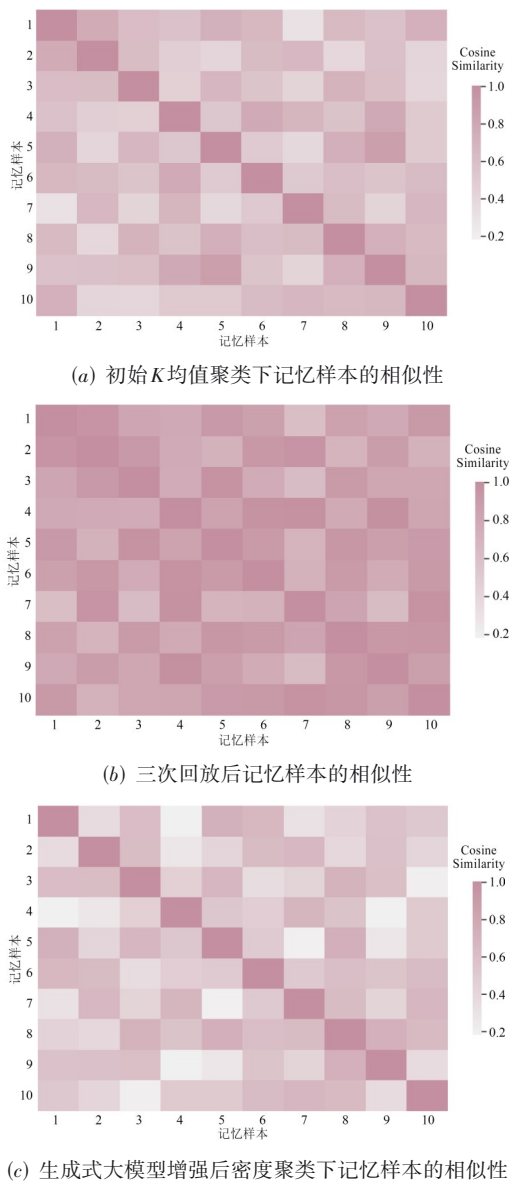


图1 记忆样本的余弦相似度热图

## 2 相关工作

### 2.1 持续关系抽取

数据科学和机器学习领域在不断发展,随着数据变得更加复杂和动态,新的挑战不断出现.在这个领域中,关系抽取(RE)是一个关键任务,它涉及从文本中识别和分类语义关系.随着数据流的持续演变,有效的持续关系抽取(CRE)的需求变得越来越重要.这个过程必须适应新的关系模式和类型,同时保留以前学习的信息.在学习新任务的同时避免灾难性地忘记旧任务是持续学习的关键挑战<sup>[15,16,20,21]</sup>.现有的CRE领域的主要模型通常分为三类:基于正则化<sup>[10,11]</sup>、动态架构<sup>[12,13,22,23]</sup>和基于记忆<sup>[5-8,17,18,24]</sup>.基于正则化方法专注于通过限制神经权重更新来保持旧任务的性能<sup>[10,11]</sup>.

动态架构方法<sup>[12,13,22,23]</sup>动态修改其模型架构以适应新任务,从而分离学习过程.

基于记忆的模型<sup>[5-8,17,18]</sup>已成为主流方法,因其在CRE方面的表现优于其他方法.基于记忆的方法<sup>[14,25-27]</sup>在新任务训练期间存储并重放以前任务的样本子集.在这些方法中,基于记忆的方法在NLP任务中显示出显著的能效<sup>[28,29]</sup>.Wu等人<sup>[7]</sup>结合课程学习和元学习来解决持续关系抽取中的顺序敏感性问题.Cui等人<sup>[8]</sup>利用关系原型和多头注意力来细化样本表示.Han等人<sup>[6]</sup>和Hu等人<sup>[17]</sup>为其模型增加了对比学习以获得更好的关系表示.Wang等人<sup>[5]</sup>引入了一个嵌入对齐模块来减少嵌入失真.Zhao等人<sup>[18]</sup>结合对比学习和知识蒸馏,以更好地保留知识.此外,Wang等人<sup>[30]</sup>引入对抗性类增强来解决类比关系中的知识遗忘问题.Huang等人<sup>[31]</sup>在2024年提出了分离式持续关系抽取(Decoupled CRE, DP-CRE)框架,该框架将先前信息的保留与新知识的获取过程分离,在新的关系类别出现时,检查嵌入空间的变化,明确区分知识的保留与获取的管理.

然而,这些方法大多忽略了两个关键问题:第一,初始训练后,典型样本通常由K均值算法选择,由于K均值(K-means)算法对初始值以及对异常值和噪声数据敏感,可能导致算法陷入局部最优而不是全局最优,所选样本不具有代表性和多样性.第二,由于模型参数的不断更新,记忆样本的不断重复播放加剧了模型过拟合的问题.这些问题在基于记忆的模型中尤为突出.为了解决这些问题,通过设计动态关系原型,利用密度峰值聚类选择代表性样本并消除对旧CRE任务的灾难性遗忘,并通过利用大语言模型中嵌入的广泛知识,通过LLM生成伪样本并将它们输入模型进行持续训练,这减轻了由模型过拟合引起的记忆样本表示偏差问题.

### 2.2 对比学习

对比学习作为一种自监督学习方法,旨在提升特征空间中不同类别样本的区分度.在持续关系抽取任务中,Zhao等人<sup>[18]</sup>利用对比学习优化原型的分布.Hu等人<sup>[17]</sup>在记忆重放阶段引入对比网络,通过增强原型与其正样本的接近度来优化样本嵌入.但是,过度的重放学习可能导致记忆样本分布不均,影响原型的代表性.Zhao等人<sup>[32]</sup>通过限制记忆样本在特征空间中的分布,确保新关系不会对旧关系的嵌入造成影响,从而增强模型性能的稳定性.尽管如此,这种方法也可能限制模型对新关系的学习能力.当模型的记忆空间受到限制时,它可能无法将学习成果泛化到新的模式上.Huang等人<sup>[31]</sup>在重放学习期间,通过解耦对比学习减少新任务样本之间的距离,同时保持记忆样本作为负锚点来增强模型的抗遗忘能力.

### 3 CRE-DCGLLM 算法

#### 3.1 问题定义

持续关系抽取(CRE)是从文本语料库中提取和更新实体之间关系的任务,随着新数据的可用性而进行更新. 本文面向句子级的持续关系抽取,形式上,CRE-DCGLLM 面临一系列单独的任务  $T=\{T_1, T_2, \dots, T_K\}$ , 对于每个任务  $T_K$ , 有唯一的数据集  $D_K$  和关系集  $R_K$ . 每个数据集  $D_K$  被划分为训练集  $D_K^{\text{Train}}$ 、验证集  $D_K^{\text{Valid}}$  和测试集  $D_K^{\text{Test}}$ , 每个单独的任务包含一系列示例  $\{(x_i, y_i)\}_{i=1}^N$ , 其中  $x_i$  表示实体对以及实体对所对应的上下文文本,  $y_i \in R_K$  是关系标签. 不同任务的关系集彼此独立. CRE-

DCGLLM 的主要目标是训练一个模型, 该模型能够顺序学习新任务, 同时保留之前学习任务的知识, 并且将在所有有已见任务的测试集集合  $\tilde{D}_K^{\text{Test}} = \cup_{i=1}^K D_i^{\text{Test}}$  上进行评估.

本文介绍了基于生成大模型增强的持续关系提取的整体框架, 如图2所示. 整体框架由两个主要流程组成.

首先是当前任务的训练. 对于当前任务  $T_K$ , 我们在  $D_K^{\text{Train}}$  上进行初始训练, 以学习这个新任务. 训练完成后, 我们应用基于密度的聚类方法选择并存储一些典型样本, 并基于这些代表样本的动态原型以及每个关系的所有训练样本的静态原型来计算任务自适应的关系原型表示  $RP_r$ . 表1介绍了本文所用到的符号及其对应的含义.

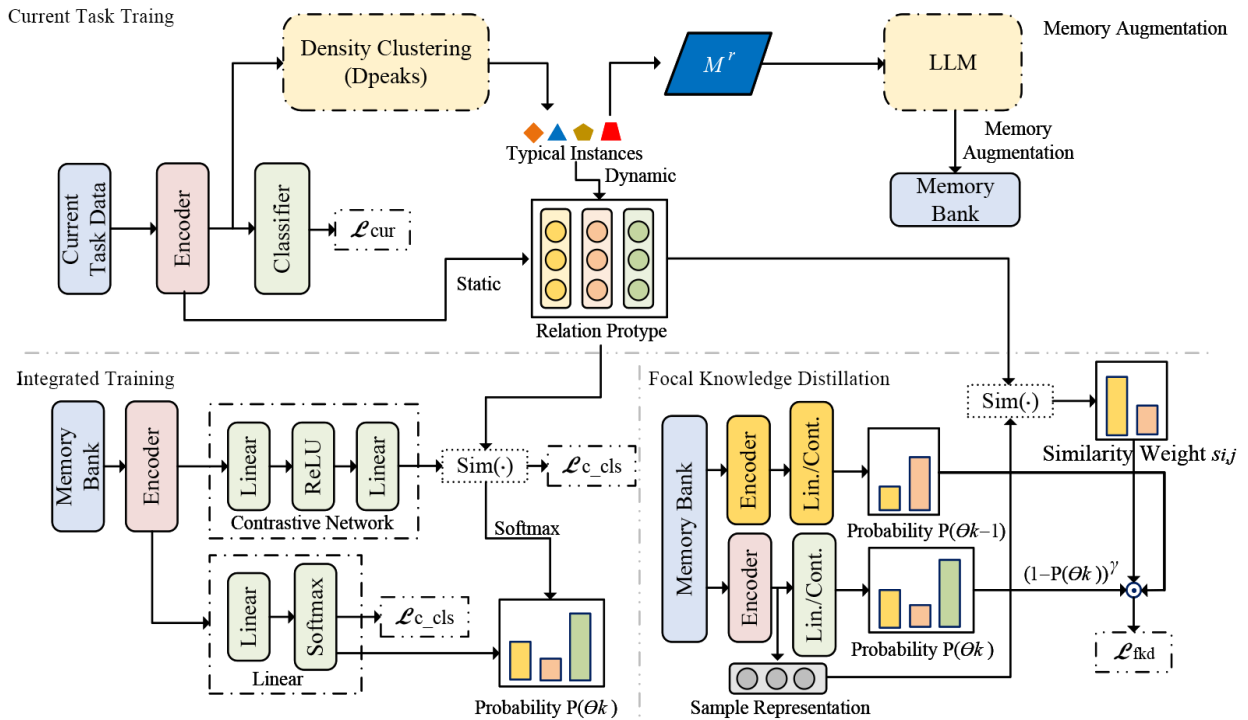


图2 CRE-DCGLLM 整体框架

其次是基于线性、对比和焦点知识蒸馏约束下的记忆重放训练. 为了保持旧分布的状态以及减轻 CRE-DCGLLM 的灾难性遗忘, 我们利用记忆样本来重新训练模型. 但是由于多次重放训练导致模型过拟合, 因此我们利用生成式大模型的数据增强方法为记忆重放提供更多的训练数据, 防止模型因反复重放而导致过拟合. 此后, 这些增强后的记忆样本, 在线性、对比和焦点知识蒸馏约束下进行了记忆重放.

#### 3.2 持续关系抽取模型 CRE-DCGLLM 的初始训练

本文首先在新任务  $T_K$  的  $D_K^{\text{Train}}$  上训练 CRE-DCGLLM 模型. 根据之前的研究, 本文选择 BERT(Bidirectional Encoder Representations from Transformers)<sup>[33]</sup> 作为编码器.

对于给定的句子  $S_i$ , 本文将其和头实体  $e_h$  和尾实体  $e_t$  共同作为模型的输入, 通过插入特殊的标记 [CLS]、[SEP]、 $[E_{11}]$ 、 $[E_{12}]$ 、 $[E_{21}]$ 、 $[E_{22}]$  来代表句子、头实体和尾实体的开始/结束位置. 具体输入序列定义如下:

$$x_{\text{input}} = \left\{ \begin{array}{l} [\text{CLS}], x_1, \dots, [E_{11}], e_h, [E_{12}], \dots, \\ [E_{21}], e_t, [E_{22}], \dots, x_n, [\text{SEP}] \end{array} \right\} \quad (1)$$

本文使用  $[E_{11}]$  和  $[E_{21}]$  的隐藏状态来表示头实体和尾实体. 然后, 表示定义如下:

$$h_{x_{\text{input}}} = \text{LayerNorm} \left( W_1 \begin{bmatrix} h_{x_{\text{input}}}^{11} \\ h_{x_{\text{input}}}^{21} \end{bmatrix} + b \right) \quad (2)$$

其中,  $[h_{x_{\text{input}}}^{11}; h_{x_{\text{input}}}^{21}]$  是头实体和尾实体的表示.  $W_1$  和  $b$  是

表 1 符号及含义

符号	含义
$T_K$	第 $K$ 个任务
$D_K, D_K^{\text{Train}}, D_K^{\text{Valid}}, D_K^{\text{Test}}$	第 $K$ 个任务的数据集,被划分为训练集、验证集和测试集
$R_K$	第 $K$ 个任务的关系集
$\hat{R}_{K-1}$	前 $K-1$ 个任务的关系集合
$\hat{M}_{K-1}$	前 $K-1$ 个任务的典型样本
$\widehat{\text{RP}}_{K-1}$	前 $K-1$ 任务的关系原型静态表示集合
$\hat{M}_K$	前 $K$ 个任务的典型样本
$\widehat{\text{RP}}_K$	前 $K$ 任务的关系原型集合
$\text{RP}_r$	任务自适应关系原型
$M_b$	增广伪样本和典型样本集合
$\tilde{M}_K$	大模型生成伪样本集合
$T_K$	第 $K$ 个任务
$D_K, D_K^{\text{Train}}, D_K^{\text{Valid}}, D_K^{\text{Test}}$	第 $K$ 个任务的数据集,被划分为训练集、验证集和测试集
$R_K$	第 $K$ 个任务的关系集

训练参数. 最后, 本文将  $h_{x_{\text{input}}}$  传递到一个线性 softmax 层来计算分类概率. 因此, 输入序列  $x_{\text{input}}$  的分类概率为

$$P(x_{\text{input}}; \theta_k) = \text{softmax}(W_2 h_{x_{\text{input}}}) \quad (4)$$

其中,  $\theta_k$  表示 CRE-DCLLM 在学习当前任务  $T_k$  时的参数.  $W_2$  是线性 softmax 层的可训练参数. 当前任务的初始训练损失计算如下:

$$\mathcal{L}_{\text{cur}} = -\frac{1}{|D_K^{\text{Train}}|} \sum_{x_i \in D_K^{\text{Train}}} \sum_{r_j \in R_k} \delta_{y_i, r_j} \log P(r_j | x_i; \theta_k) \quad (4)$$

其中,  $P(r_j | x_i; \theta_k)$  是当前模型使用参数  $\theta_k$  将输入序列  $x_i$  分类为关系  $r_j$  的分类概率;  $y_i$  是输入序列中头实体  $e_h$  和尾实体  $e_t$  的真实标签. 如果  $y_i = r_j$ , 则  $\delta_{y_i, r_j} = 1$ , 否则等于 0.

### 3.3 任务自适应的关系原型表示

在学习了当前任务  $T_k$  之后, 为了保留从先前任务中学到的知识, 对于每个关系  $r$ , 本文选择并存储一些典型的样本以供记忆重放. 先前的工作采用了  $K$ -均值算法将样本聚类成  $L$  个簇. 然而, 通过随机选择初始簇中心会导致局部最优, 使得选取的样本缺乏代表性, 从而引起模型对旧任务的性能下降. 受到 DPeak 算法<sup>[34]</sup> 的启发, 本文采用基于密度聚类的方式选取记忆样本.

对于当前任务  $T_k$  下的关系  $y_i$  的每一个样本  $x_i$ , 样本  $x_i$  的局部密度定义为

$$\rho_{x_i} = \sum_{(x_j \in D_K^{\text{Train}}) \wedge (x_i, x_j \in y_i)} e^{-\left(\frac{d_{ij}}{d_c}\right)^2} \quad (5)$$

其中,  $d_{ij}$  表示  $x_i$  和  $x_j$  的相似度.  $d_c$  表示截断距离.

$$\delta_{x_i} = \min_{k: \rho_{x_i} \geq \rho_{x_j}} (d_{i,k}) \quad (6)$$

对于具有最高密度的样本  $x_i$ , 本文通常取  $\delta_{x_i} = \max_k (d_{i,k})$ . 结合这两个指标, 具有高局部密度和低相对距离的数据是应该被选择的代表性样本, 典型样本的数量被定义为记忆大小  $m$ .

以往的研究通常通过平均典型样本的表示来计算关系  $r$  的原型, 并直接用于分类. 然而, 这种推导关系原型的方法对典型样本的质量非常敏感, 有可能导致原型表示的偏差. 为了减轻这种敏感性, Zhang 等人<sup>[35]</sup> 引入一种利用知识生成关系原型的方法, 利用关系定义文本和知识提示来指导原型的生成. 然而, 这种知识注入技术并不能解决典型样本分布质量带来的偏差. 例如, 通过聚类算法选出的典型样本可能在某些区域过于集中, 而在另一些区域则比较稀疏, 而且这些集中的区域可能会随着不断学习的过程变得越来越集中. 从这些样本中直接计算原型可能导致原型偏离真正的中心. 为了减少这种偏差, 本文首先计算并存储学习关系后所有训练样本的平均表示, 称为完全原型 (静态表示), 它包含了更全面的关系知识.

本文采用了针对关系  $r$  的任务自适应关系原型, 它使用典型样本的动态表示来微调关系原型的静态表示. 任务自适应关系原型定义如下:

$$\text{RP}_r = \alpha \frac{\sum_{x_i \in M^r} z_{x_i}}{|M^r|} + (1 - \alpha) \text{RP}_r^{\text{static}} \quad (7)$$

其中,  $\text{RP}_r^{\text{static}}$  是关系  $r$  的全部训练样本的平均表示.  $z_{x_i}$  是存储在记忆库中关系  $r$  的典型样本.  $\alpha$  是超参数.

### 3.4 基于生成大模型增强的记忆样本重回放

由于内存空间的限制, 每个关系  $r$  的这些典型样本可能会被多次重放, 导致模型过拟合. 因此, 本文利用一个大型语言模型 (Qwen-Chat<sup>[19]</sup>, 14 B 规模模型) 来生成用于记忆增强的样本, 从而提供了更多的训练样本用于记忆重放. 本文首先用记忆中获得的任务的关系名称来填充如图 3 所示的指令提示模板  $T$ . 接下来, 本文基于指令提示模板, 将这些提示输入到生成器中, 以获得关系  $r$  的通用伪样本. 尽管一些伪样本被输入到模型中, 但模型的目的也是识别关系  $r$ . 本文在所有旧任务上执行这种增强策略, 每个任务有 10 个伪样本. 重要的是, 这些伪样本仅用于模型的持续训练, 不参与关系原型的计算.

在学习新任务之后, 通常会进行记忆样本的重放, 以减轻编码器对旧任务知识的遗忘. 本文采用对比学习和焦点知识蒸馏进行联合重放训练<sup>[18]</sup>, 使用 InfoNCE 损失和三元组损失进行对比学习训练.




图3 基于生成式大语言模型的记忆样本增强

$$\mathcal{L}_{C\_cls} = -\frac{1}{|\hat{M}^k|} \sum_{x_i \in \hat{M}^k} \log \frac{\exp\left(z_{x_i} \cdot \frac{z_{y_i}}{\tau}\right)}{\sum_{r \in \hat{R}^k} \exp\left(z_{x_i} \cdot \frac{z_r}{\tau}\right)} \quad (8)$$

$$+ \frac{\mu}{|\hat{M}^k|} \sum_{x_i \in \hat{M}^k} \max(\omega - z_{x_i} z_{y_i} + z_{x_i} z_{y_i'}, 0)$$

其中,  $z_{x_i}$  表示  $\text{MLP}(h_{x_i})$  的归一化,  $z_r$  是关系  $r$  的低维原型表示.  $y_i' = \arg \max_{y_i' \in \hat{R}^k} (z_{x_i} \cdot z_{y_i'})$  是样本  $x_i$  最负面的关系标签.  $\tau$  是温度系数.  $\omega$  和  $\mu$  是超参数.

此外,在线性损失中,线性分类器获得的关系概率与新任务训练步骤中获得的关系概率相似. 损失函数  $\mathcal{L}_{L\_cls}$  如下:

$$\mathcal{L}_{L\_cls} = -\frac{1}{|\hat{M}^k|} \sum_{x_i \in \hat{M}^k} \sum_{r_j \in \hat{R}_k} \delta_{y_i, r_j} \log P(r_j | x_i; \theta_k) \quad (9)$$

在持续训练过程中,一些新出现的关系与其他已学习的关系相似,难以区分. 我们采用了焦点知识蒸馏,这迫使模型更多地关注类似关系. 具体来说,我们为每个样本-关系对分配一个独特的权重,根据样本的分类概率以及样本和关系原型之间表示的相似性,使困难的样本和类似的样本-关系对被赋予高权重. 对于样本  $x_i$ , 关系  $r_j$  的权重  $\omega_{x_i, r_j}$  的公式如下:

$$s_{x_i, r_j} = \frac{\exp\left(\frac{\text{sim}(x_i, \text{RP}_{r_j})}{\tau_1}\right)}{\sum_{r_m \in \hat{R}_{k-1}} \exp\left(\frac{\text{sim}(x_i, \text{RP}_{r_m})}{\tau_1}\right)} \quad (10)$$

$$\omega_{x_i, r_j} = s_{x_i, r_j} \left(1 - P(y_i | x_i; \theta_k)\right)^\gamma \quad (11)$$

其中,  $\text{RP}_{r_j}$  和  $\text{RP}_{r_m}$  是关系  $r_j$  和  $r_m$  的原型,  $\text{sim}(\cdot)$  是余弦相似度函数,  $\tau_1$  是温度参数,  $\gamma$  是超参数.

使用计算得到的权重,分别在对比和线性条件下的焦点知识蒸馏的损失函数如下:

$$\alpha_{x_i, r_j}^c = \omega_{x_i, r_j} P(r_j | x_i; \theta_{k-1}) \quad (12)$$

$$\mathcal{L}_{C\_fkd} = -\frac{1}{|\hat{M}^k|} \sum_{x_i \in \hat{M}^k} \sum_{r_j \in \hat{R}_{k-1}} \alpha_{x_i, r_j}^c \log P_c(r_j | x_i; \theta_k) \quad (13)$$

$$\alpha_{x_i, r_j}^l = \omega_{x_i, r_j} P(r_j | x_i; \theta_{k-1}) \quad (14)$$

$$\mathcal{L}_{L\_fkd} = -\frac{1}{|\hat{M}^k|} \sum_{x_i \in \hat{M}^k} \sum_{r_j \in \hat{R}_{k-1}} \alpha_{x_i, r_j}^l \log P_l(r_j | x_i; \theta_k) \quad (15)$$

因此,整体的回放训练损失如下:

$$\mathcal{L}_{\text{replay}} = \mathcal{L}_{C\_cls} + \mathcal{L}_{L\_cls} + \lambda_1 \mathcal{L}_{C\_fkd} + \lambda_2 \mathcal{L}_{L\_fkd} \quad (16)$$

在学习任务  $T_k$  之后,对于每个测试样本  $x_i^*$ ,通过比较其嵌入与所有关系原型来获取最终关系标签.

$$y_i^* = \arg \max_{y_i^* \in \hat{R}^k} \left( (1-\beta) P_c(x_i^*; \theta_k) + \beta P_l(x_i^*; \theta_k) \right) \quad (17)$$

其中,  $P_c(x_i^*; \theta_k)$  和  $P_l(x_i^*; \theta_k)$  分别是通过对比方法和线性方法计算出的概率.  $\beta$  是一个超参数.

CRE-DCGLLM 中学习当前任务  $T_k$  的过程详见算法 1.

#### 算法 1 CRE-DCGLLM 中学习当前任务 $T_k$ 的过程

**输入:** 当前任务的训练集  $D_k^{\text{train}}$ ; 关系集合  $R_k$ ; 前  $K-1$  任务的关系集合  $\hat{R}_{K-1}$ ; 前  $K-1$  任务的典型样本  $\hat{M}_{K-1}$ ; 前  $K-1$  任务的关系原型静态表示集合  $\widehat{\text{RP}}_{K-1}$ ; 编码器  $E(\cdot)$

**输出:**  $\hat{M}_K$ ,  $\hat{R}_K$ ,  $\widehat{\text{RP}}_K$ ,  $\text{RP}_r$ , 编码器  $E(\cdot)$

1. IF  $T_k$  不是第一任务 THEN
2. 用前  $K-1$  任务的典型样本  $\hat{M}_{K-1}$  得到的模型进行初始化  $E(\cdot)$ ;
3. END IF
4.  $M_b \leftarrow E(D_k^{\text{train}})$ ;
5. 采用  $\mathcal{L}_{\text{cur}}$  损失更新  $E(\cdot)$  和  $M_b$ ;
6. FOR 每一个关系  $r \in R_k$  DO
7. 计算静态关系原型  $\text{RP}_r^{\text{static}}$ ;
8.  $M_r \leftarrow M_r \cup \text{RP}_r^{\text{static}}$
9. END FOR
10.  $\widehat{\text{RP}}_K \leftarrow \widehat{\text{RP}}_{K-1} \cup M_r$ ;
11. 采用密度聚类算法,从  $D_k^{\text{train}}$  中为每一个关系  $r$  选择  $K$  个代表样本  $M_k$ ;
12.  $\hat{M}_K \leftarrow \hat{M}_{K-1} \cup M_k$ ;
13.  $\hat{R}_K \leftarrow \hat{R}_{K-1} \cup R_k$ ;
14. 采用大模型为每一个关系  $r \in \hat{R}_K$  生成伪样本  $\tilde{M}_k$ ;
15. IF  $T_k$  不是第一任务 THEN
16.  $M_b \leftarrow \hat{M}_K \cup \tilde{M}_k$ ;
17. 采用  $\mathcal{L}_{\text{replay}}$  损失更新  $E(\cdot)$ ;
18. END IF
19. 为每一个关系  $r$ , 采用式(6)和式(7)计算任务自适应关系原型  $\text{RP}_r$ ;
20. RETURN  $\hat{M}_K$ ,  $\hat{R}_K$ ,  $\widehat{\text{RP}}_K$ ,  $\text{RP}_r$ , 编码器  $E(\cdot)$

## 4 实验结果与分析

本节首先介绍了实验的评价指标与数据集及实验设置,并与当前主流的方法做出了对比,给出了实验结果. 其次,在验证集上给出了消融实验,并给出了各个

模块的有效性对比. 最后, 本文给出了实例结果, 并对实例结果进行分析.

## 4.1 评价指标与数据集

### 4.1.1 评价指标-Accuracy

本文采用两种评估设置, 包括整体性能和平均性能. 整体性能计算所有任务在整个测试集上的准确率, 而平均性能则是对所有已见任务的准确率进行平均. 在处理完所有任务后, 本文使用最终的整体性能和平均性能来评估持续关系学习的总体表现. 鉴于平均性能能够有效反映模型应对灾难性遗忘问题的能力, 它成为了评价模型的关键指标. 相较于其他指标, 平均准确率更能准确反映灾难性遗忘对模型的影响, 因为它着重考察了模型对初始任务的保持情况.

### 4.1.2 数据集

本研究的实验基于两个业界公认的标准数据集展开. 训练集、测试集和验证集的划分比例为 3:1:1.

#### (1) FewRel 数据集

FewRel<sup>[35]</sup>是专门为关系抽取(RE)任务设计的. 它包含 80 种不同的关系, 每种关系由 700 个实例表示. 在本文的实验中, 遵循文献[18]的设置, 使用覆盖所有 80 个类别的原始 FewRel 训练和验证集.

#### (2) TACRED 数据集

TACRED<sup>[36]</sup>是一个大规模的关系抽取数据集, 包含 42 种关系和 106 264 个样本. 该数据集的特点是不同关系间的样本分布不均衡.

## 4.2 实验设置

本文的实验设置遵循了最近研究<sup>[18]</sup>中建立的标准, 采用完全随机的关系级采样策略. 在这种策略中, 数据集中的所有关系被随机分成 10 组, 每组代表一个独特的任务, 以模拟一系列 10 个持续学习任务. 本文在实验中使用相同的随机种子设置, 以确保任务序列的一致性和比较的公平性.

在训练阶段, 本文在一块拥有 48 GB 内存的 NVIDIA RTX A6000 GPU 上进行所有实验, 并使用 BERT-base<sup>[33]</sup>作为编码器, 以及学习率为  $5 \times 10^{-6}$  的 Adam 优化器进行梯度更新. 批量大小设置为 16, 权重因子  $\alpha$  和  $\beta$  设置为 0.6 和 0.4. 温度参数  $\tau$  和  $\tau_1$  设置为 0.08 和 0.1,  $\omega$  和  $\mu$  分别设置为 0.1 和 0.5.  $\gamma$ ,  $\lambda_1$  和  $\lambda_2$  为超参数, 分别取 1.5、0.5 以及 0.7. 主要结果的记忆样本(每个关系类型)大小设置为 10.

## 4.3 主体实验

本文的方法与以下基线方法进行比较.

(1) EA-EMR<sup>[5]</sup>: Wang 等人在 2019 年通过正则化项提出嵌入对齐模型, 以减轻嵌入失真.

(2) EMAR<sup>[6]</sup>: 2020 年 Han 等人在模型中加入了对比学习, 以更好地表示关系, 有效缓解灾难性遗忘.

(3) CML<sup>[7]</sup>: Wu 等人于 2021 年结合了课程学习和元学习来解决 CRE 中的顺序敏感性问题.

(4) RP-CRE<sup>[8]</sup>: Cui 等人在重放学习期间添加注意力模块, 以原型细化样本嵌入.

(5) CRECL<sup>[17]</sup>: 2022 年 Hu 等人提出了一个分类网络和一个原型对比网络, 以在对比学习下实现 CRE 的增量类别学习.

(6) CRL<sup>[18]</sup>: 结合了对比学习和知识蒸馏, 以更好地保留知识.

(7) KIP-Framework<sup>[37]</sup>: 通过生成融入知识关系原型, 并利用提示调整来利用 PLM 中的关系知识, 从一个新的角度研究 CRE.

(8) CEAR<sup>[32]</sup>: Zhao 等人在 2023 年提出一种新颖的持续抽取模型, 具有对记忆不敏感的关系原型和用于类似关系的记忆增强.

(9) DP-CRE<sup>[31]</sup>: Huang 等人在 2024 年提出分离式持续关系提取框架, 该框架将先前信息的保留与新知识的获取过程分离. 在新关系类别出现时, 检查嵌入空间的变化, 明确区分知识的保留与获取的管理.

本文通过使用不同的随机种子进行 10 次实验, 在验证集上报告了平均值和标准差. 在 FewRel 数据集上的实验结果表明, 不同的持续关系抽取 (CRE) 方法在面对连续学习任务时的表现各异. 从表 2 中可以看出, EA-EMR 和 EMAR 方法在任务 1 (T1) 上取得了相对较高的准确率, 分别为 89.0% 和 88.5%. 但随着任务的增加, 其准确率逐渐下降, 尤其是在 T10 时, 准确率降到了 35.2% 和 46.3%. 这可能表明这些方法在处理新任务时遗忘了之前学习的知识, 即遭受了灾难性遗忘.

EMAR (BERT) 方法在所有任务中表现最为出色, 准确率始终保持在 98.8% 以上, 这可能是因为 BERT 模型的强大语言理解能力为关系抽取任务提供了更丰富的上下文信息. CML 方法结合了课程学习和元学习, 但在 T10 的准确率也只有 39.7%, 虽然比 EA-EMR 和 EMAR 有所提高, 但仍有改进空间.

RP-CRE 和 CRECL 方法利用了关系原型和多头注意力机制来改善样本表示, 它们在 T1 的准确率分别为 97.9% 和 97.8%, 并且在后续任务中保持了相对稳定的性能. CRL 方法结合了对比学习和知识蒸馏, 其在 T1 的准确率为 98.2%, 在后续任务中也显示出较好的稳定性.

KIP-Framework 通过生成知识丰富的关系原型来处理 CRE 任务, 其在 T1 的准确率为 98.4%, 但在后续任务中的表现略有下降. CEAR 方法通过区分类似关系来提高 CRE 的性能, 其准确率在 T1 为  $98.1 \pm 0.6\%$ , 并且在后续任务中保持了较小的标准差, 显示出较好的稳定性和鲁棒性. DP-CRE 的策略是在新任务学习时, 通过解耦学习机制来平衡新旧任务的学习, 这种方法有助

表2 在数据集 FewRel 上的实验结果

单位:%

方法	T1	T2	T3	T4	T5	T6	T7	T8	T9	T10
EA-EMR	89.0	69.0	59.1	54.2	47.8	46.1	43.1	40.7	38.6	35.2
EMAR	88.5	73.2	66.6	63.8	55.8	54.3	52.9	50.9	48.8	46.3
EMAR(BERT)	<b>98.8</b>	89.1	89.5	85.7	83.6	84.8	79.3	80.0	77.1	73.8
CML	91.2	74.8	68.2	58.2	53.7	50.4	47.8	44.4	43.1	39.7
RP-CRE	97.9	92.7	91.6	89.2	88.4	86.8	85.1	84.1	82.2	81.5
CRECL	97.8	94.9	92.7	90.9	89.4	87.5	85.7	84.6	83.6	82.7
CRL	98.2	94.6	92.5	90.5	89.4	87.9	86.9	85.6	84.5	83.1
KIP-Framework	98.4	93.5	92.0	91.2	90.0	88.2	86.9	85.6	84.1	82.5
CEAR	98.1±0.6	<u>95.8±1.7</u>	93.6±2.1	91.9±2.0	<u>91.1±1.5</u>	<u>89.4±2.0</u>	<u>88.1±1.5</u>	86.9±1.3	85.6±0.8	84.2±0.4
DP-CRE	98.5	95.4	<u>93.7</u>	<b>92.1</b>	90.9	<u>89.4</u>	<b>88.5</b>	<b>87.4</b>	<u>86.3</u>	<b>85.1</b>
CRE-DCGLLM	<u>98.2±0.7</u>	<u>97.5±0.4</u>	<u>96.3±1.2</u>	<b>94.2±1.7</b>	<b>92.6±1.9</b>	<b>89.9±1.3</b>	<b>88.5±0.6</b>	<u>87.1±1.0</u>	<b>86.4±0.7</b>	84.8±1.2

注:加粗字体表示最佳结果,下划线表示次佳结果.

于模型在不断学习新任务的同时,保持对旧任务的记忆,在 FewRel 数据集上的实验结果表明了其在新旧任务平衡的优势.

CRE-DCGLLM 方法在大多数任务中都取得了最高的平均准确率,并且在标准差方面也表现出较小的波动,这表明本文的方法在处理持续关系抽取任务时能够有效地减少灾难性遗忘和过拟合问题.特别是在 T10 任务中,CRE-DCGLLM 的准确率为 84.8±1.2%,比其他方法高出几个百分点,这一性能上的显著提升,证明了本文方法的有效性,尤其是在长期持续学习场景中.因此,CRE-DCGLLM 通过结合密度聚类 and 生成式大型语言模型,有效地减少了对旧任务的灾难性遗忘,这是其在长期任务中保持高性能的关键因素.动态关系原

型和焦点知识蒸馏技术的运用,进一步提升了 CRE-DCGLLM 对变化中关系模式的适应性能.

在 TACRED 数据集上的实验结果显示了各 CRE 方法在处理关系抽取任务时的性能差异.从表 3 中可以看出,EA-EMR 方法的准确率从 T1 的 47.5% 逐渐下降至 T10 的 19.8%,这表明其在连续学习过程中遗忘了较多之前学习的知识.EMAR 方法在 T1 上的表现略好于 EA-EMR,但同样面临准确率随任务增加而下降的问题.EMAR(BERT)方法利用了 BERT 模型的强大能力,在 T1 上达到了 96.6% 的高准确率,并且在后续任务中相对稳定,显示出 BERT 模型在提供上下文信息方面的优势.CML 方法虽然结合了课程学习和元学习,但其准确率在 T10 仅为 23.4%,说明其在持续学习任务中的表现有限.

表3 在数据集 TACRED 上的实验结果

单位:%

方法	T1	T2	T3	T4	T5	T6	T7	T8	T9	T10
EA-EMR	47.5	40.1	38.3	29.9	24	27.3	26.9	25.8	22.9	19.8
EMAR	73.6	57.0	48.3	42.3	37.7	34.0	32.6	30.0	27.6	25.1
EMAR(BERT)	96.6	85.7	81	78.6	73.9	72.3	71.7	72.2	72.6	71.0
CML	57.2	51.4	41.3	39.3	35.9	28.9	27.3	26.9	24.8	23.4
RP-CRE	97.6	90.6	86.1	82.4	79.8	77.2	75.1	73.7	72.4	72.4
CRECL	96.6	93.1	89.7	87.8	85.6	84.3	<u>83.6</u>	<u>81.4</u>	79.3	78.5
CRL	97.7	93.2	89.8	84.7	84.1	81.3	80.2	79.1	79.0	78.0
KIP-Framework	<u>98.3</u>	95.0	90.8	87.5	85.3	84.3	82.1	80.2	79.6	78.6
CEAR	97.7±1.6	<u>94.3±2.9</u>	<u>92.3±3.3</u>	<u>88.4±3.7</u>	<u>86.6±3.0</u>	<u>84.5±2.1</u>	82.2±2.8	81.1±1.6	80.1±0.7	79.1±1.1
DP-CRE	97.8	93.8	91.5	87.5	85.7	84.2	<u>82.9</u>	81.3	<u>81.5</u>	<b>80.7</b>
CRE-DCGLLM	<b>98.5±0.3</b>	<b>95.5±0.4</b>	<b>93.3±1.2</b>	<b>90.2±2.7</b>	<b>89.3±2.3</b>	<b>87.2±1.7</b>	<b>84.1±3.6</b>	<b>83.1±1.9</b>	<b>81.7±1.3</b>	<u>79.9±1.4</u>

注:加粗字体表示最佳结果,下划线表示次佳结果.

RP-CRE 和 CRECL 方法通过改进样本表示取得了较好的结果,其中 RP-CRE 在 T1 的准确率为 97.6%,CRECL 为 96.6%,两者在后续任务中均保持了较高的准确率.CRL 方法结合了对比学习和知识蒸馏,在 T1 上达到了 97.7% 的准确率,并在后续任务中维持了较好的性能.

KIP-Framework 方法通过生成知识丰富的关系原型,在 T1 上取得了 98.3% 的准确率,但在后续任务中准确率有所下降.CEAR 方法在 T1 上准确率为 97.7±1.6%,并且在后续任务中保持了较小的标准差,显示出较好的稳定性.DP-CRE 也展示了在持续关系抽取任务

中的有效性,特别是在处理新旧任务平衡、抗遗忘能力以及过拟合问题上采取了不同的策略。

最后,本文提出的 CRE-DCGLLM 方法在大多数任务中都取得了最高的平均准确率,特别是在 T1 上达到了  $98.5 \pm 0.3\%$ ,在 T10 上也有  $79.9 \pm 1.4\%$  的表现,这表明本文的方法在处理连续关系抽取任务时能够有效地减轻灾难性遗忘和过拟合问题。CRE-DCGLLM 方法在准确率上的优势以及在标准差上的稳定性,证明了其在持续学习环境中的强大性能和适应性。这些结果强调了本文方法在提高关系抽取任务中的准确性和效率方面的潜力,特别是在处理类似关系和防止知识遗忘方面的显著优势。

#### 4.4 消融实验与记忆样本大小影响分析

通过在 FewRel 和 TACRED 数据集上的消融实验,可以观察到每个组件对模型性能的具体影响。这些实验结果强调了所提出方法中各个部分的重要性,以及它们在提高持续关系抽取任务中的准确性和效率方面所起到的关键作用。通过这些实验,我们可以更好地理解模型的工作原理,并给未来的改进工作提供了指导。

表 4 展示了在 FewRel 和 TACRED 数据集上进行的消融实验结果,这些实验分别移除了密度聚类(w/o DC)、动态关系原型(w/o DRP)和生成式大型模型(w/o LLM)的使用,以评估这些组件对本文提出方法(Ours)的性能的影响。

表 4 在数据集 FewRel 和 TACRED 上的消融实验结果

FewRel										
方法	T1	T2	T3	T4	T5	T6	T7	T8	T9	T10
Ours	<b>98.2</b>	<b>97.5</b>	<b>96.3</b>	<b>94.2</b>	<b>92.6</b>	<b>89.9</b>	<b>88.5</b>	<b>87.1</b>	<b>86.4</b>	<b>84.8</b>
w/o DC	98.1	94.5	92.5	89.9	88.3	87.4	86.4	84.5	84.0	83.1
w/o DRP	98.2	95.8	94.7	92.3	90.1	89.3	87.4	86.2	85.7	83.6
w/o LLM	98.2	94.6	92.6	90.7	89.9	88.5	87.4	86.2	84.8	83.6

TACRED										
方法	T1	T2	T3	T4	T5	T6	T7	T8	T9	T10
Ours	<b>98.5</b>	<b>95.5</b>	<b>93.3</b>	<b>90.2</b>	<b>89.3</b>	<b>87.2</b>	<b>84.1</b>	<b>83.1</b>	<b>81.7</b>	<b>79.9</b>
w/o DC	97.1	94.1	86.3	85.6	84.7	83.1	81.2	80.1	79.7	78.8
w/o DRP	98.5	95.0	92.1	89.7	87.9	85.6	83.1	82.9	80.6	79.8
w/o LLM	97.8	94.1	90.9	86.8	85.6	83.9	81.6	80.4	80.2	79.4

注:加粗字体表示实验结果,其他为消融实验结果。

在 FewRel 数据集上,与完整模型相比,移除密度聚类(w/o DC)后,模型的准确率从 T1 的 98.2% 下降到 T10 的 83.1%,这表明密度聚类在提高模型对旧任务的记忆力方面起到了重要作用。类似地,移除动态关系原型(w/o DRP)也导致了准确率的下降,尤其是在后期的任务中。这证实了动态关系原型对于适应新任务和保留旧任务知识的重要性。然而,不使用生成式大模型

(w/o LLM)对性能的影响相对较小,表明其他组件在一定程度上补偿了这一缺失。

在 TACRED 数据集上,移除密度聚类(w/o DC)同样导致了准确率的显著下降,尤其是在 T4 之后的任务中,进一步强调了密度聚类在处理关系不平衡问题中的有效性。移除动态关系原型(w/o DRP)对性能的影响相对较小,但在 T10 任务中准确率下降到 79.8%,这可能与 TACRED 数据集的特点有关。不使用生成式大模型(w/o LLM)对性能的影响在 TACRED 数据集上比 FewRel 数据集上更为显著,尤其是在后期的任务中,这表明生成式模型在增强模型对新任务的适应性和防止过拟合方面起到了重要作用。

总体而言,消融实验结果表明,CRE-DCGLLM 方法中每个组件都对模型的整体性能有积极贡献。特别是密度聚类在提高模型的记忆力和适应性方面起到了关键作用,而动态关系原型和生成式大语言模型则有助于模型更好地处理新任务和防止过拟合。这些发现强调了在设计持续关系抽取模型时考虑这些组件的重要性。

记忆大小,定义为每个关系存储的典型样本数量,是记忆型持续关系抽取(CRE)模型性能的一个关键指标。为了评估本文模型对记忆大小的敏感性,本文进行了不同记忆大小(2、5、10 和 15)的实验。最终结果如图 4 和图 5 所示。

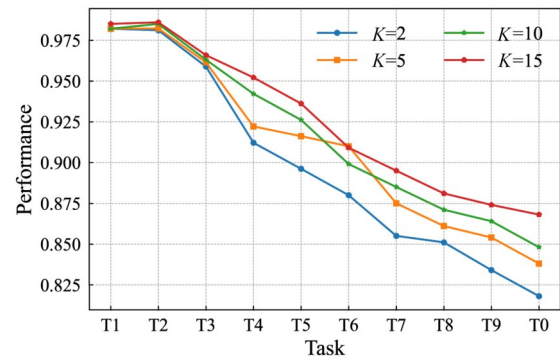


图 4 在数据集 FewRel 上内存大小之间的精度差异




图 5 在数据集 TACRED 上内存大小之间的精度差异

随着记忆大小的减小,两个模型的性能都有所下降.然而,一个关键的观察是,本文的模型在几乎所有测试的记忆大小上始终优于CRL模型.此外,随着记忆大小的减小,本文的方法的性能下降得不那么剧烈,特别是在TACRED数据集上.这表明本文的方法具有更好的稳定性,对记忆大小的敏感性较低.

通过上述案例研究,直观地说明了本文模型的优越性.我们选择了涉及3个高度相似组的10个关系,即[(0)director,(1)screenwriter,(2)country of origin,(3)location,(4)location of formation,(5)headquarters of location,(6)mouth of the watercourse,(7)tributary,(8)located in or next to body of water,(9)crosses].图6描述了关系原型之间余弦相似度可视化结果.从图6可以看出,语义相似的关系(如“河道口”和“支流”)具有相对相似的关系原型,这反映出本文模型学习了一个合理的表示空间.此外,可以看到相似关系原型(如“director”和“screenwriter”)之间的区分仍然很明显,这表明本文模型能够区分类比关系.




图6 关系原型之间余弦相似度的可视化

## 5 结论

本文探讨了基于记忆的重放方法中灾难性遗忘和过拟合问题带来的挑战.通过实证研究,本文发现记忆样本的表示偏差和过拟合以及初始样本的选择是CRE中灾难性遗忘的主要原因.为此,本文提出了一种新颖的持续实体关系抽取方法来解决上述问题.具体来说,本文应用密度聚类并设计动态关系原型来减轻旧任务的灾难性遗忘.通过生成式大模型建模来设计记忆增强,以克服过拟合问题.本文还利用焦点知识提炼来提高演化关系模式的性能.通过在FewRel数据集和TACRED数据集上的广泛实验,证明了本文方法的有效性.研究结果在持续关系抽取的准确性和效率上显示出显著的改进,

特别是在处理类似关系、防止知识遗忘和克服过拟合方面.

## 参考文献

- [1] 隗昊,唐焕玲,周爱,等.基于双路分段注意力神经张量网络的临床文本关系抽取[J].电子学报,2023,51(3):658-665.  
WEI H, TANG H L, ZHOU A, et al. Clinical relation extraction via dual piecewise attention neural tensor network[J]. Acta Electronica Sinica, 2023, 51(3): 658-665. (in Chinese)
- [2] 王宇,王震,温立强,等.DRE-3DC:基于三维表征建模的篇章级关系抽取模型[J].电子学报,2024,52(9):2950-2960.  
WANG Y, WANG Z, WEN L Q, et al. DRE-3DC: Document-level relation extraction with three-dimensional representation combination modeling[J]. Acta Electronica Sinica, 2024, 52(9): 2950-2960. (in Chinese)
- [3] ZHOU P, SHI W, TIAN J, et al. 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: ACL, 2016: 207-212.
- [4] BALDINI SOARES L, FITZGERALD N, LING J, et al. Matching the blanks: Distributional similarity for relation learning[C]//Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. Stroudsburg: ACL, 2019: 2895-2905.
- [5] WANG H, XIONG W H, YU M, et al. Sentence embedding alignment for lifelong relation extraction[C]//Proceedings of the 2019 Conference of the North. Stroudsburg: ACL, 2019: 796-806.
- [6] HAN X, DAI Y, GAO T Y, et al. Continual relation learning via episodic memory activation and reconsolidation[C]//Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. Stroudsburg: ACL, 2020: 6429-6440.
- [7] WU T T, LI X K, LI Y-F, et al. Curriculum-meta learning for order-robust continual relation extraction[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(12): 10363-10369.
- [8] CUI L, YANG D Q, YU J X, et al. Refining sample embeddings with relation prototypes to enhance continual relation extraction[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and

- the 11th International Joint Conference on Natural Language Processing. Stroudsburg: ACL, 2021: 232-243.
- [9] HASSABIS D, KUMARAN D, SUMMERFIELD C, et al. Neuroscience-inspired artificial intelligence[J]. *Neuron*, 2017, 95(2): 245-258.
- [10] PFULB B, GEPPERTH A. Overcoming catastrophic forgetting with Gaussian mixture replay[C]//2021 International Joint Conference on Neural Networks. Piscataway: IEEE, 2021: 1-9.
- [11] ZENKE F, POOLE B, GANGULI S. Continual learning through synaptic intelligence[C]//Proceedings of the 34th International Conference on Machine Learning - Volume 70. New York: ACM, 2017: 3987-3995.
- [12] CHEN T Q, GOODFELLOW I, SHLENS J. Net2Net: Accelerating learning via knowledge transfer[EB/OL]. (2016-04-23)[2024-05-20]. <https://arxiv.org/abs/1511.05641>.
- [13] FERNANDO C, BANARSE D, BLUNDELL C, et al. PathNet: Evolution channels gradient descent in super neural networks[EB/OL]. (2017-01-30)[2024-04-08]. <https://arxiv.org/abs/1701.08734>.
- [14] CHAUDHRY A, RANZATO M, ROHRBACH M, et al. Efficient Lifelong Learning with A-GEM[EB/OL]. (2019-01-09)[2024-05-20]. <https://arxiv.org/abs/1812.00420>.
- [15] VERWIMP E, DE LANGE M, TUYTELAARS T. Rehearsal revealed: The limits and merits of revisiting samples in continual learning[C]//2021 IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE, 2022: 9365-9374.
- [16] DE LANGE M, ALJUNDI R, MASANA M, et al. A continual learning survey: Defying forgetting in classification tasks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44(7): 3366-3385.
- [17] HU C, YANG D, JIN H, et al. Improving continual relation extraction through prototypical contrastive learning[EB/OL]. (2022-10-10)[2024-05-20]. <https://arxiv.org/abs/2210.04513>.
- [18] ZHAO K, XU H, YANG J G, et al. Consistent representation learning for continual relation extraction[C]//Findings of the Association for Computational Linguistics. Stroudsburg: ACL, 2022: 3402-3411.
- [19] BAI J Z, BAI S, CHU Y F, et al. Qwen technical report[EB/OL]. (2023-09-28)[2024-05-20]. <https://arxiv.org/abs/2309.16609>.
- [20] PARISI G I, KEMKER R, PART J L, et al. Continual lifelong learning with neural networks: A review[J]. *Neural Networks*, 2019, 113: 54-71.
- [21] HSU Y C, LIU Y C, RAMASAMY A, et al. Re-evaluating continual learning scenarios: A categorization and case for strong baselines[EB/OL]. (2019-01-23)[2024-04-08]. <https://arxiv.org/abs/1810.12488>.
- [22] MALLYA A, LAZEBNIK S. PackNet: Adding multiple tasks to a single network by iterative pruning[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 7765-7773.
- [23] QIN Q, PENG H, HU W R, et al. BNS: Building network structures dynamically for continual learning[C]//Advances in Neural Information Processing Systems 34 (NeurIPS 2021). Trier: DBLP, 2021: 20608-20620.
- [24] 赵基藤, 李国正, 汪鹏, 等. 基于监督对比重放的持续关系抽取[J]. *中文信息学报*, 2023, 37(11): 60-67, 80.
- ZHAO J T, LI G Z, WANG P, et al. Continual relation extraction via supervised contrastive replay[J]. *Journal of Chinese Information Processing*, 2023, 37(11): 60-67, 80. (in Chinese)
- [25] LOPEZ-PAZ D, RANZATO M. Gradient episodic memory for continual learning[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. New York: ACM, 2017: 6470-6479.
- [26] REBUFFI S A, KOLESNIKOV A, SPERL G, et al. iCaRL: Incremental classifier and representation learning[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2017: 5533-5542.
- [27] MAI Z D, LI R W, KIM H, et al. Supervised contrastive replay: Revisiting the nearest class mean classifier in online class-incremental continual learning[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Piscataway: IEEE, 2021: 3584-3594.
- [28] SUN F K, HO C H, LEE H Y. LAMOL: LAnguage modeling for lifelong language learning[EB/OL]. (2019-12-23)[2024-05-20]. <https://arxiv.org/abs/1909.03329>.
- [29] D'AUTUME C de M, RUDER S, KONG L, et al. Episodic memory in lifelong language learning[EB/OL]. (2019-11-26)[2024-05-20]. <https://arxiv.org/abs/1906.01076>.
- [30] WANG P Y, SONG Y F, LIU T Y, et al. Learning robust representations for continual relation extraction via adversarial class augmentation[C]//Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2022: 6264-6278.
- [31] HUANG M Y, XIAO M, WANG L D, et al. DP-CRE: Continual relation extraction via decoupled contrastive learning and memory structure preservation[EB/OL]. (2024-03-05)[2024-05-20]. <https://arxiv.org/abs/2403.02718>.

- [32] ZHAO W Z, CUI Y N, HU W. Improving continual relation extraction by distinguishing analogous semantics[C]// Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics. Stroudsburg: ACL, 2023: 1162-1175.
- [33] DEVLIN J, CHANG M W, LEE K, et al. BERT: Pre-training of deep bidirectional transformers for language understanding[EB/OL]. (2019-05-24)[2024-09-28]. <https://arxiv.org/abs/1810.04805>.
- [34] RODRIGUEZ A, LAIO A. Clustering by fast search and find of density peaks[J]. Science, 2014, 344(6191): 1492-1496.
- [35] HAN X, ZHU H, YU P F, et al. FewRel: A large-scale supervised few-shot relation classification dataset with state-of-the-art evaluation[C]// Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2018: 4803-4809.
- [36] ZHANG Y H, ZHONG V, CHEN D Q, et al. Position-aware attention and supervised data improve slot filling[C]// Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2017: 35-45.
- [37] ZHANG H, LIANG B, YANG M, et al. Prompt-based prototypical framework for continual relation extraction[J]. IEEE/ACM Transactions on Audio, Speech and Language Processing, 2022, 30: 2801-2813.

### 作者简介



钟 将 男, 1974 年 4 月出生于重庆市. 重庆大学计算机学院教授、博士生导师, 在国内外发表学术论文 120 余篇. 主要研究方向为自然语言处理、数据挖掘、机器学习等.

E-mail: zhongjiang@cqu.edu.cn



戴启祝 男, 1995 年 4 月出生于江苏省盐城市. 2024 年毕业于重庆大学计算机学院获博士学位, 现为马上消费金融股份有限公司博士后. 主要研究方向为自然语言处理.

E-mail: 1092864172@qq.com



李 雪 男, 1955 年出生于重庆市. 昆士兰大学教授、博士生导师. 主要研究方向为社交网络分析、分布式高速时变数据流的知识挖掘.

E-mail: xueli@itee.uq.edu.au