

基于预训练语言模型的端到端概念体系构建方法*

王思懿^{1,2}, 何世柱^{1,2}, 刘康^{1,2}, 赵军^{1,2}

¹中国科学院自动化研究所, 复杂系统认知与决策实验室

²中国科学院大学, 人工智能学院

wangsiyi2021@ia.ac.cn, {shizhu.he, kliu, jzhao}@nlpr.ia.ac.cn

摘要

概念体系是一种重要的知识资源, 描述了概念之间的上下位关系并以层次结构进行组织。本文致力于研究概念体系的自动构建技术, 旨在将给定的概念集合按照上下位关系组织成树状的概念体系(概念树)。传统方法通常将概念体系构建任务分解成两个独立的子任务: 概念间上下位语义关系的判断和概念层次结构的生成任务。然而, 这两个子任务缺乏信息反馈, 容易导致错误累积等问题。近年来, 使用预训练语言模型获取词语的语义特征、判断词语之间的语义关系已经成为一种流行的方法, 在概念体系构建任务中取得了一定的效果, 但是这种方法只能对第一个子任务进行建模, 并且仍然存在错误累积的问题。为了解决这个问题并有效地获取词语及其关系的语义特征, 本文提出了一种基于预训练语言模型的端到端概念体系构建方法。该方法一方面利用预训练语言模型获取概念及其上下位关系的语义信息和部分概念体系的结构信息, 另一方面, 利用强化学习端到端地建模概念关系的判断和完整体系结构的生成。在WordNet数据集上进行的实验表明, 本文提出的方法取得了良好的效果。在相同条件下, 本文方法比最好模型在F1值上能取得7.3%的相对性能提升。

关键词: 概念体系构建; 强化学习; 预训练语言模型

End to End Taxonomy Construction Method with Pretrained Language Model

Siyi Wang^{1,2}, Shizhu He^{1,2}, Kang Liu^{1,2}, Jun Zhao^{1,2}

¹The Laboratory of Cognition and Decision Intelligence for Complex Systems, Institute of Automation, Chinese Academy of Sciences, Beijing, China

²School of Artificial Intelligence, University of Chinese Academy of Sciences, Beijing, China
wangsiyi2021@ia.ac.cn, {shizhu.he, kliu, jzhao}@nlpr.ia.ac.cn

Abstract

Concept system is an important knowledge resource, which describes the Hyponymy and hypernymy between concepts and organizes them in a hierarchical structure. This paper focuses on the automatic construction technology of concept system, aiming to organize the given concept set into a tree like concept system (generalization tree) according to the Hyponymy and hypernymy. Traditional methods usually decompose the task of building a conceptual system into two independent subtasks: determining the semantic relationships between concepts, and generating conceptual hierarchical structures. However, the lack of information feedback in these two subtasks can easily lead

*本论文受到国家重点研发计划项目(2022ZD0160503), 国家自然科学基金项目(U1936207, 61976211), 中国科学院青年创新促进会和云南省重大科技专项(No.20220AD080004)资助。

to issues such as error accumulation. In recent years, using pre trained language models to obtain semantic features of words and determine semantic relationships between words has become a popular method, which has achieved certain results in concept system construction tasks. However, this method can only model the first subtask and still has the problem of error accumulation. In order to solve the problem of error accumulation in step-by-step methods and effectively obtain the semantic features of words and their relationships, this paper proposes an end-to-end conceptual architecture construction method based on pre-trained language models. On the one hand, this method uses the pre-trained language model to obtain the semantic information of concepts and their hyponymy and hypernymy and the structural information of some conceptual systems; on the other hand, it uses Reinforcement learning to model the judgment of conceptual relationships end-to-end and the generation of complete architectures. The experiments conducted on the WordNet dataset show that the proposed method has achieved good results. Under the same conditions, the proposed method can achieve a relative performance improvement of 7.3% on F1 values compared to the best model.

Keywords: Taxonomy Induction , Reinforcement Learning , Pretrained Language Model

1 引言

概念体系使用层次结构描述概念之间的上下位语义关系，是一类重要的知识体系，属于有向图的一种 (Yang and Ni, 2022)，被广泛的用于问答系统、信息检索 (Demeester et al., 2016; Yang et al., 2017)等任务中，例如，在医疗概念体系用于组织和管理疾病。同时，大量神经网络模型也常利用概念体系的知识内容增强语义表达能力。但是目前各类应用系统中的概念体系主要由人工完成，例如，语言概念体系WordNet (Miller, 1995)和常识概念体Cyc (Lenat, 1995)等完全由人工构建，DBpedia (Auer et al., 2007)中的概念体系是工程师通过观察Wikipedia中的标签 (Tag) 体系信息的组织方式及命名后总结得到，Schema.org¹中类型、属性和关系的定义及规范由众多科技公司协商得到。这种方式不仅费时费力，构建的概念体系还常常存在概念遗漏的情况，使得更新和维护成本高昂，因此亟需设计和实现概念体系的自动构建方法。

传统方法将自动构建概念体系的任务分为两个独立的子任务，即上下位关系判断和概念体系构建。上下位关系判断任务通过基于模式的方法从大型语料库中提取候选词语对，并形成带有噪声的概念体系图，然后采用不同的修剪算法来提取树状概念体系 (Granot and Huberman, 1981)。然而，这种方法存在一些缺陷。首先，词语的上下位关系判断任务仅仅预测词语对的上下位关系概率，忽略了概念体系的结构信息。其次，在构建概念体系的第二个子任务中，使用固定的词语对特征表示，该特征表示是由第一个子任务产生的，缺乏跨任务的反馈修正，因而存在错误传播问题 (Sun et al., 2022)。

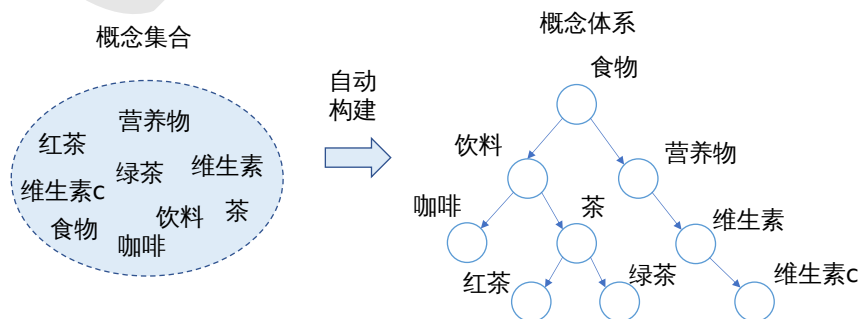


图 1: 概念体系构建示意图

强化学习在自然语言处理领域 (Sun et al., 2022)应用十分广泛 (Kwan et al., 2023)，为了解决这些问题，有研究提出了一种基于强化学习的联合建模方法 (Mao et al., 2018)，即利用强化

¹<https://schema.org>

学习的策略网络逐步构建概念体系。然而，该方法中的词语选择过程缺乏已构建概念体系的信息，并且词语的特征向量表示是固定的，因此所取得的效果受到一定限制。在预训练语言模型被提出后 (Kenton and Toutanova, 2019)，其被广泛应用于分类和语言表示等任务。为了获得更好的效果，CTP (Constructing Taxonomies from Pretrained Language Models) (Chen et al., 2021)将上下位关系判断任务转化为二分类任务，取得了WordNet数据集上最佳的成果。然而，由于CTP是分步式的，仍然存在错误累积问题。

我们提出了一种名为基于预训练语言模型的端到端概念体系自动构建方法 (E2TCM, End-to-End Taxonomy Construction with Pretrained Language Model)，旨在解决现有方法的局限性。E2TCM利用预训练语言模型学习词语对的特征表示，并通过特定的动作（如概念选择、概念剔除、上位词节点选择等）来实现从集合到树结构-“Set to Tree”的映射，这一过程通过强化学习完成。为了更好地利用概念体系的信息，我们将语义特征和结构特征进行融合，得到概念体系的特征向量。同时，我们将该特征向量与待预测上下位关系的词语对特征向量进行联合表示，以提高预测的准确性。借助策略网络，我们可以精确地预测应选择哪个词语以及它在概念体系中的位置，并将反馈传递回特征学习模块来调整预训练语言模型对词语对特征的学习。所有模块都以端到端的方式进行训练，并累积每一步的奖励，直到形成完整的概念体系，并用于更新模型的所有参数。我们在公开数据集上进行了实验验证，结果表明所提出的方法是有效的。

我们的贡献可以总结为以下几点：

- 1.首次将预训练语言模型的端到端方法应用于概念体系自动构建任务，并且提出一种通用型框架，可有效提升模型的精度。

- 2.在强化学习动作预测中充分利用了已构建的部分概念体系的特征信息。我们使用可见矩阵将二维的树结构转换为自然语言形式，将概念体系的语义特征和结构信息结合，提取到概念体系的特征向量并有力支撑端到端概念体系自动构建。

- 3.我们在公开的WordNet数据集进行了实验，结果表明，我们的方法相比经典方法TaxoRL (End-to-End Reinforcement Learning for Automatic Taxonomy Induction) (Mao et al., 2018)有13.4%的绝对提升，相比基于预训练模型的CTP方法 (Chen et al., 2021)也有7.3%的性能提升 (F1)。

2 相关工作

在图1中，我们展示了概念体系自动构建任务的流程图。任务包含两部分，首先是从给出的语料库中提取概念词语对，然后将提取到的概念词语集合按照上下位关系，组织成树状的概念体系。概念体系自动构建的方法可以大致分为基于模式的方法和基于分布的方法。

基于模式的方法主要用于从大型语料库中提取可能具有上下位关系的词语对 (Hearst, 1992; Snow et al., 2004; Kozareva and Hovy, 2010; Panchenko et al., 2016; Nakashole et al., 2012)，Hearst模式是指词语对的句法模式，也就是说如果一个句子中的一对词语符合某种形式，就可以认为他们是上下位关系，例如，“是一种”、“是一部分”等表示。有学者 (Snow et al., 2004)提出了一种系统，基于上述模式预测词语之间的关系。分布式方法则考虑词语的上下文，此时不需要词语对在句子中共存，有一些无监督方法 (Chang et al., 2017)和有监督方法 (Luu et al., 2016)。一些研究 (Aldine et al., 2021)使用基于顺序模式挖掘的新型三段式方法，改进了基于模式的方法的低召回率问题。我们主要研究如何将一组概念词语组织成概念体系形式。有学者将任务看作结构化的学习问题 (Bansal et al., 2014)，使用概率模型公式组织概念体系，使用循环信念传播整体考虑节点在树中的兄弟关系。有人将图神经网络应用于概念层次构建任务 (Shang et al., 2020)，用迁移学习的方式，提高了在SemEval-2016 Task 13数据集上构造大型概念体系的性能。

在基于分布的方法中，为了改进词语的特征表示，还有一些方法将词语的表示转换到双曲空间进行 (Aly et al., 2019; Torregrossa et al., 2021; Aly et al., 2019)使用双曲空间对树结构进行编码，得到词语在双曲空间中的表示，改进了 (Panchenko et al., 2016; Tan et al., 2016)等的分类结果，证明了双曲空间更适合描述树结构。此外，CTP模型 (Chen et al., 2021)使用预训练语言模型判断词语对的上下位关系，并且使用计算词语相似度的方法解决一词多义问题，取得了很好的效果；TaxoRL模型 (Mao et al., 2018)使用强化学习实现了端到端的分类体系构建法。

还有一些相关的工作则通过考虑使用概念体系节点的兄弟和祖先关系进行分类扩展 (Wang

et al., 2022; Zhang et al., 2021; Wang et al., 2021; Jiang et al., 2022)。分类扩展任务是在已有概念体系的基础上添加节点，使得概念体系更加完善，以前的分类扩展任务只将新添加的节点作为叶节点 (Wang et al., 2021)，这与我们的做法类似，在训练过程中，我们同样将带添加的节点只作为叶节点添加到已有分类书中，有研究 (Zhang et al., 2021) 提出，在扩展概念体系时，新节点不应只作为叶节点，也可以作为父节点插入到已存在的边中。QEN算法 (Wang et al., 2022) 在TMN算法的基础上额外考虑了兄弟节点信息。

这些方法都存在一些问题，大部分都是将任务分为两个子任务的做法，而这种做法存在错误累积问题；TaxoRL (Mao et al., 2018) 忽略了概念体系的信息，且过度依赖于外部信息，这些都限制了模型的效果。

3 基于预训练语言模型的概念体系自动构建方法

任务定义 我们定义一个概念体系 $T = (V, R)$ ，其中， T 表示概念树节点集合， R 表示概念树的边的集合。对于树中任意一个节点 $v \in V$ ， v 可以是一个单个词语或者是多个词语组成的词组。我们的任务是，将给定的概念集合按照上下位关系组织成树状的概念体系。

为了实现端到端概念体系构建，我们以强化学习技术为核心，联合建模概念上下文关系判断和完整概念树构建两个任务，本小节将具体介绍网络的实现。我们使用预训练语言模型对动作矩阵和概念树进行编码，将二者特征结合后通过两层神经网络得到模型选择每个词语的概率，图2所示的动作过程根据每个词语的概率大小做出选择，最终得到类似图5中的概念树。我们将详细介绍我们如何设计的动作、状态和奖励函数。

3.1 概念树构建动作空间

概念体系构建过程是一系列动作的组合。在每个时间步 t 中， T_t 表示此时已构建的概念树， V_t 表示剩余的概念集合，也就是还未加入 T_t 中的词语，我们定义的动作：(1) 从词汇表 V_t 中选择一个词语 x_1 ；(2) 将 x_1 从词汇表 V_t 中移除；(3) 将 x_1 添加到 T_t 中，作为节点 x_2 的下位词。动作空间的大小为 $|V_t| \times |T_t|$ ，其中 $|V_t|$ 表示剩余词汇表 V_t 中词语的数量大小， $|T_t|$ 表示现有概念体系中节点的大小。回合开始时，概念集合 V_0 大小等于输入词汇表， T_0 被初始化为空集合。在每个时间步 t ， $|V_t| = |V_{t-1}| - 1$ ， $|T_t| = |T_{t-1}| + 1$ 都始终成立，且 $|V_t| + |T_t| = |V_0|$ 。当一个回合完成后，词汇表中的所有词语都被添加到了概念体系中。

在图2中，我们使用一个例子介绍了上述的动作过程，初始状态为某时刻词汇表与概念体系的状态，词汇表中灰色划线的词语表示已经从词汇表中被删除，我们可以看到这些被删除的词语已经被组织成了右图的概念树；动作1为从词汇表中选择词语“咖啡”，动作2将“咖啡”删去，动作3将“咖啡”连接到“饮料”，作为其子节点，经过一个完整的动作，模型的状态由初始状态变为一个时间步之后的状态。圆圈中的数字表示词语被选择的顺序。

对于如何向概念体系中添加第一个节点，我们选择在一个回合开始时，随机选择一个词语作为根节点，并且在每一步选择词语时，允许新的词语作为当前根节点的上位词，也就是作为新的根节点。这样缓解了选择第一个节点时缺乏先验知识的问题，动作空间大小变为 $|A_t| = |V_t| \times |T_t| + |V_t|$ 。由于每一步词汇表的大小都会发生改变，因为在选择添加新的词语时，并非单独选择一个词语，而是列出概念体系 T_t 和词汇表 V_t 中所有词语的可能组合 (x_v, x_t) ，选择词语对时，就已经确定了新选择的词语在概念体系 T_t 中的位置。

3.2 概念树构建状态建模

我们将每个时刻的已构建概念树 T_t ，概念集合 V_t 及其特征定义为状态。状态作为指导模型的重要因素，其特征的好坏对实验结果有极大影响。下面我们将介绍如何得到概念树的特征及动作矩阵的特征。如图4中所示，模型通过预训练语言模型获得树状概念体系的特征和词语的特征，然后将其输入策略网络中，策略网络通过处理得到的特征选择词语构建概念体系。

动作矩阵 动作矩阵也可以叫做词语对矩阵，其中的每一行都是一个词语对组成的句子“Term1 IS A Term2”（例如，“A cat is a mamal”，表示cat是mamal的下位词），其中Term1一般从词汇表中提取，Term2则从已构建概念树的节点集合中提取。为了得到词语对的特征，我们将动作矩阵输入到预训练语言模型中（如BERT），提取其中的隐藏层向量作为特征。实验证明，不同的句子形式不影响模型的特征提取结果，比如“Term1 a type of Term2”，“Term1 an example of Term2”等。

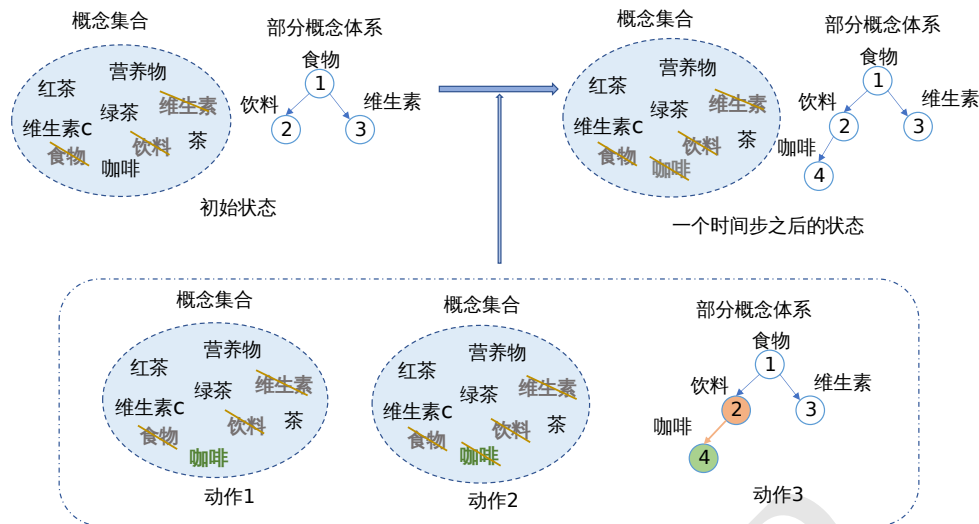


图 2: 每个时间步的概念树状态转变过程

树的特征 使用预训练语言模型可以方便地提取句子的特征，因为句子是一维的。然而，对于树状结构的概念体系，我们很难使用提取词语对特征的方法来提取树的特征。我们甚至很难定义树的特征，因为树状概念体系的特征不仅包括二维结构特征，还包括每个节点本身的语义特征。因此，如何将这两者融合起来是一个棘手的问题。

我们使用可视矩阵的方法 (Liu et al., 2020)，将概念体系的树状结构转换为词语之间能否相互“看见”的状态。我们认为，如果一对词语之间存在上下位关系，那么它们在语义上也一定存在很强的相关性，因此使这样的词语在可视矩阵中相互可见。在图3中展示了一个树状概念体系与其可视矩阵的示意图，我们使得有上下位关系的词语相互可见，因此可视矩阵是对称矩阵，矩阵的横轴和纵轴均表示树状概念体系的所有节点，矩阵 (i, j) 处的值为1时表示第 i 个节点可以“看见”第 j 个节点，值为0时表示“看不见”。通过将可视矩阵与树状概念体系同时输入预训练语言模型中，我们得到了概念体系的语义和结构相融合的特征。

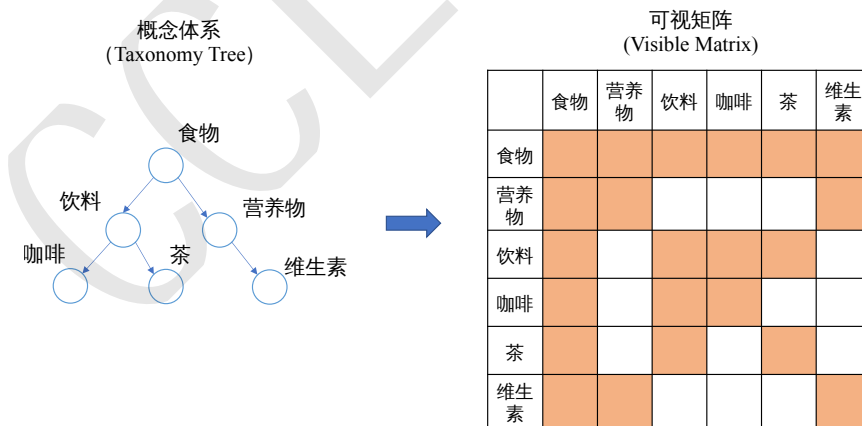


图 3: 概念树状态构建中的可视矩阵

3.3 概念树构建奖励函数

模型为了学习如何选择更好的动作，每进行一次动作都需要给予标量的奖励。一般会结果的衡量指标作为奖励，也就是最终生成概念体系后，比较预测结果和标签的F1值，将其作为奖励。但是这种方式不能表现每一步动作选择的好坏，具有延迟性。因此我们计算每个动作执行前后概念树的F1值，将此差值作为奖励。也就是 $r_t = F1_{e_t} - F1_{e_{t-1}}$ 。如果当前的F1值比上一次的时间好，奖励就为正，否则就为负。REINFORCE (Williams, 1992)算法的特点就是当完成一个回合后才会更新网络，即中间步骤的奖励不会即刻影响后续动作，而是在完成树的构建

后用所有奖励的集合更新策略网络。这样做的好处是，模型可以整体的考虑生成效果，而不是只考虑当前动作的好坏，某些动作在当下的收益可能一般，但在长远角度看来会带来更大的收益。




图 4: 概念树构建的策略网络结构图

3.4 概念树构建策略网络及模型训练

定义了动作、状态和奖励之后，我们将介绍如何设计模型的策略网络来选择每一步的动作。网络 $\pi(a|S, U)$ 的作用是根据输入给出选择每一个动作的概率，动作空间大小随着状态的改变而改变，网络输入为动作特征矩阵，其结构如图4所示。结合所有词语对的向量后得到动作矩阵 A_t ，其尺寸为 $|V_t| \times |T_t| + |V_t| \times \dim(P)$ ，其中 $|V_t| \times |T_t| + |V_t|$ 表示动作维度，也就是所有词语对的数目， $\dim(P)$ 表示词语对的特征向量维度。对于每个时刻得到的概念体系 T_t ，可视矩阵记为 Vm_t ，大小为 $|T_t| \times |T_t|$ 。将概念体系 T_t 的节点与对应的可见矩阵输入到预训练语言模型中，就可以得到概念体系的特征向量 S_t ，将 A_t 与 S_t 一起输入到策略网络中。

策略网络由两部分组成，一个单层的前向传播网络和一个两层的前向传播网络。 S_t 由单层前向传播网络后，与 A_t 结合，再经由两层前向传播网络，最后经过softmax层，得到动作的概率分布 P_t ，大小为 $|V_t| \times |T_t|$ 。模型将根据 P_t 选择动作也就是词语对，模型具体计算过程如下：

$$S_t = Relu(M_s + b_s)$$

$$\pi(a|S, U) = softmax(M_U^2(Relu(M_U^1(A_t; S_t) + b_U^1)) + b_U^2)$$

$$a_t \sim \pi(a|S, U)$$

其中， M_s 和 M_U 均表示前向传播的网络的参数， U 表示策略梯度网络的参数。在训练阶段，我们根据概率分布对动作进行采样，但是在测试阶段则是选择概率最高的动作。

我们选择REINFORCE算法作为优化算法，是策略梯度算法的一种。策略网络参数的更新如下：

$$U = U + \alpha \sum_{t=1}^T \nabla \pi(a_t|S, U) \cdot v_t$$

其中， $v_k = \sum_{t=1}^T \gamma^{t-k}$ 是完成一个回合后的累计奖励， $\gamma \in [0, 1]$ 是折现因子，表示未来对现在的影响。

同时为了减小方差且使得模型更充分的学习每个样本，我们将每个样本训练十次后，将所得奖励的平均值作为基线。

4 实验

4.1 数据集

我们使用从WordNet中提取的数据集，该数据集是由 (Bansal et al., 2014) 创建的中等大小的数据集，数据集涵盖各种领域，比如动物，食物，日常用品等等。数据集全部是由高度为4的中等大小的子树组成（将根节点的高度记为1，从根节点出发到达叶节点的最长路径为4），子树大小（子树拥有的所有节点个数）为均在10到50之间，子树之间互相没有重叠。数据集包含761棵树，我们将其按照训练集、验证集和测试集三类划分成533/114/114大小。

4.2 评价指标

Ancestor-F1. 我们沿用之前工作的评价指标 (Bansal et al., 2014)，该指标将预测概念体系(prediction tree)的祖先对与标准概念体系(gold tree)的祖先对进行比较，我们使用 P_a , R_a 和 $F1_a$ 表示准确率、召回率和F1值：

$$P_a = \frac{|IS - A_{prediction} \cap IS - A_{gold}|}{|IS - A_{prediction}|}$$

$$R_a = \frac{|IS - A_{prediction} \cap IS - A_{gold}|}{|IS - A_{gold}|}$$

则可以得到 $F1_a = \frac{2P_a R_a}{P_a + R_a}$ ，其中 $IS - A_{prediction}$ 和 $IS - A_{gold}$ 分别表示预测的上下位关系和正确的上下位关系。

Edge-F1. 这个评价指标只比较预测概念体系的边（也就是上下位关系的边）和标准概念体系的边。我们使用 P_e , R_e , $F1_e$ 表示，其具体计算方式与上式类似。根据指标的公式可以看出，当预测结果与标准概念体系大小一致时， $P_e = R_e = F1_e$ 。

我们用 $F1_e$ 计算强化学习的奖励值，使用 $F1_a$ 作为评价指标衡量模型结果。

4.3 实验结果与分析

我们与两个典型模型进行对比：1) TaxoRL，基于端到端的概念体系自动构建方法；2) CTP，基于预训练语言模型的概念体系自动构建方法。表1中展示整体实验结果，对比了本文方法和对比方法。（我们在实验过程中使用的预训练语言模型是bert-base-uncased计算资源有限不能运行更大规模的模型），为了更加客观的比较我们的方法与CTP方法，在这里我们对比的CTP也是使用bert-base-uncased模型。从表中可以看出，在使用同样的预训练语言模型条件下，我们的方法有最高的F1值，相比CTP有7.2%的相对提升。在CTP中，预训练语言模型用于估计词语之间的上下位关系的概率，并且使用二分类的方式对其进行微调。为了得到每一对词语之间上下位关系的概率，需要先得到所有可能的词语对，对于一个大小为 n 的集合，其可能的词语对有 $\frac{n!}{2}$ ，而其中正确的仅有 $n - 1$ 对，其余均为负样本，存在严重的样本不平衡问题，将会影响预训练语言模型的判断能力，且由于分步式的缺陷，判断的错误后续无法改正。而我们将预训练网络嵌入到端到端模型中，如图4中所示，使用整体的损失微调预训练语言模型，使得预训练网络的错误可以用后续结果的反馈进行修正。为了更合理的比较模型，我们采用TaxoRL未使用额外信息时的结果，我们的方法相比之下有12.4%的绝对提升，

| Model | P | R | F1 |
|------------------------|-------------|-------------|-------------|
| TaxoRL | 41.3 | 49.2 | 44.9 |
| CTP(bert-base-uncased) | 57.9 | 51.8 | 53.4 |
| Ours | 56.6 | 58.0 | 57.3 |

表 1: 我们的方法在英文数据集上与以往方法的比较结果

4.4 消融实验

这一小节我们探究概念体系特征对于模型的作用。表2展示了我们在WordNet数据集上进行的消融实验。Glove+RL是使用Glove提取词语对的特征向量（实际上这就是TaxoRL的框架

| Model | P | R | F1 |
|--------------|-------------|-------------|-------------|
| Glove+RL | 41.3 | 49.2 | 44.9 |
| PLM(CTP) | 57.9 | 51.8 | 53.4 |
| PLM+RL | 58.7 | 53.2 | 55.8 |
| PLM+RL+State | 56.6 | 58.0 | 57.3 |

表 2: 不同模型的结果比较

结构), 当我们使用PLM作为提取特征向量的网络时, 评价结果有了10.9%的极大提升, 证明了预训练语言模型对词语特征表达更合理。相比仅使用预训练语言模型, 我们将其与端到端方式结合后, 评价结果提升2.4%, 证明端到端方式可以更好的微调预训练语言模型的对词语的特征表示。当我们使用概念体系的特征时, 结果又有1.5%的提升, 说明我们定义的概念体系特征中包含有利于分类的结构信息。另外, 我们还注意到加入状态特征 (state) 后, 与CTP结果相比, 模型的召回率增加但精确率降低。我们认为这可能是因为在使用PLM判断词语之间的上下位关系时, 缺乏上下文信息, 即概念树的特征信息, 导致一些不明显的上下位关系被错误地判断为非上下位关系。然而, 当增加状态特征 (state) 后, 模型可以利用词语对的上下文信息来判断它们之间的关系, 从而正确地判断一些不明显的上下位关系, 因此召回率增加。但同时精确率也下降。这可能是导致该现象发生的原因。

| State | P | R | F1 |
|-------|-------------|-------------|-------------|
| 0 | 58.7 | 53.2 | 55.8 |
| 50 | 54.9 | 57.1 | 56.0 |
| 100 | 56.6 | 58.0 | 57.3 |
| 500 | 54.6 | 57.3 | 55.9 |
| 768 | 51.8 | 54.7 | 53.2 |

表 3: 状态维度不同时时的结果

状态维度分析 我们使用BERT模型提取概念树的原始特征为768维, 在图4中可以看到, 在融合概念树特征和动作特征前, 我们将其经过了一个非线性的单层前向神经网络, 为了探究这一步的效果, 我们进行了如表3所示的对比试验。表3的左侧列表指的是前向神经网络输出的维度, 0表示不使用该特征, 768表示不经过神经网络直接与动作矩阵结合。

可以看出, 模型的效果随着网络输出维度的增大呈现先上升后下降的趋势。使用 $A_t = [a_1; a_2; \dots; a_{|T_t|}]$ 表示动作特征矩阵, 其中 $|a_i| = 768$, 用 S_t 表示概念树特征。直接将二者结合的结果为 $G_t = [a_1, S_t; a_2, S_t; \dots; a_i, S_t]$ 。策略网络决策的主要参考依据是 A_t , S_t 仅起到补充作用, 维度过大时将严重影响 A_t 的特征表示, 因此当其维度为768时, 反而降低了模型的效果, 而当维度适中时, 既可以起到补充信息的作用, 又不会影响 A_t 的原有特征, 因此可以有效地提升效果。




图 5: 训练过程实例

训练实例 我们在图5中展示了训练过程的实例。图5(a)中, 红色虚线为连接错误的边, 蓝色虚线为正确的缺失的边, 蓝色的实线为预测正确的边。图5(b)中节点的数字表示该节点加入概念树的先后顺序。在图5(a)中, 策略网络错误的将“咖啡”节点先于“饮料”节点添加到概念树

中，造成了错误的边，“维生素”和“绿茶”等也同理。这是由于策略网络根据给出的特征认为“咖啡-食物”的概率比“饮料-食物”更高，然而在受到反馈后策略网络和特征提取网络同时调整参数，使得“饮料-食物”的概率更高，在图5(b)中，策略网络调整了“咖啡”与“饮料”的选择顺序，更改了之前的错误，其他的错误节点也同样会在后续得到修改。这就是我们的模型相比分步式方法的优势。

5 总结与展望

在本文中，我们提出了基于预训练语言模型的端到端概念体系构建方法，相比同等条件下的方法取得了更好的结果，且我们的模型为通用模型框架，可以任意更改预训练语言模型。但是由于实际设备限制，目前难以使用大模型。在未来我们将进一步探索更合理的动作设计（比如新的节点不仅可以作为叶节点，也可以插入已有的边中作为其他节点的父节点），如何更加充分的利用已构建概念体系的信息（例如，将节点与兄弟节点和祖先节点的关系纳入考虑）以及设置合理的奖励函数。

参考文献

- Aldine, A. I. A., Harzallah, M., Berio, G., Béchet, N., and Faour, A. (2021). A 3-phase approach based on sequential mining and dependency parsing for enhancing hypernym patterns performance. *The Knowledge Engineering Review*, 36:e13.
- Aly, R., Acharya, S., Ossa, A., Köhn, A., Biemann, C., and Panchenko, A. (2019). Every child should have parents: A taxonomy refinement algorithm based on hyperbolic term embeddings. In *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*, pages 4811–4817.
- Auer, S., Bizer, C., Kobilarov, G., Lehmann, J., Cyganiak, R., and Ives, Z. (2007). Dbpedia: A nucleus for a web of open data. In *The Semantic Web: 6th International Semantic Web Conference, 2nd Asian Semantic Web Conference, ISWC 2007+ ASWC 2007, Busan, Korea, November 11-15, 2007. Proceedings*, pages 722–735. Springer.
- Bansal, M., Burkett, D., De Melo, G., and Klein, D. (2014). Structured learning for taxonomy induction with belief propagation. In *Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pages 1041–1051.
- Chang, H.-S., Wang, Z., Vilnis, L., and McCallum, A. (2017). Unsupervised hypernym detection by distributional inclusion vector embedding. *arXiv preprint arXiv:1710.00880*.
- Chen, C., Lin, K., and Klein, D. (2021). Constructing taxonomies from pretrained language models. In *Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, pages 4687–4700.
- Demeester, T., Rocktäschel, T., and Riedel, S. (2016). Lifted rule injection for relation embeddings. In *Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing*, pages 1389–1399.
- Granot, D. and Huberman, G. (1981). Minimum cost spanning tree games. *Mathematical programming*, 21:1–18.
- Hearst, M. A. (1992). Automatic acquisition of hyponyms from large text corpora. In *COLING 1992 Volume 2: The 14th International Conference on Computational Linguistics*.
- Jiang, M., Song, X., Zhang, J., and Han, J. (2022). Taxoenrich: Self-supervised taxonomy completion via structure-semantic representations. In *Proceedings of the ACM Web Conference 2022*, pages 925–934.
- Kenton, J. D. M.-W. C. and Toutanova, L. K. (2019). Bert: Pre-training of deep bidirectional transformers for language understanding. In *Proceedings of NAACL-HLT*, pages 4171–4186.
- Kozareva, Z. and Hovy, E. (2010). A semi-supervised method to learn and construct taxonomies using the web. In *Proceedings of the 2010 conference on empirical methods in natural language processing*, pages 1110–1118.

- Kwan, W.-C., Wang, H.-R., Wang, H.-M., and Wong, K.-F. (2023). A survey on recent advances and challenges in reinforcement learning methods for task-oriented dialogue policy learning. *Machine Intelligence Research*, 20(3):318–334.
- Lenat, D. B. (1995). Cyc: A large-scale investment in knowledge infrastructure. *Communications of the ACM*, 38(11):33–38.
- Liu, W., Zhou, P., Zhao, Z., Wang, Z., Ju, Q., Deng, H., and Wang, P. (2020). K-bert: Enabling language representation with knowledge graph. In *Proceedings of the AAAI Conference on Artificial Intelligence*, volume 34, pages 2901–2908.
- Luu, A. T., Tay, Y., Hui, S. C., and Ng, S. K. (2016). Learning term embeddings for taxonomic relation identification using dynamic weighting neural network. In *Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing*, pages 403–413.
- Mao, Y., Ren, X., Shen, J., Gu, X., and Han, J. (2018). End-to-end reinforcement learning for automatic taxonomy induction. In *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pages 2462–2472.
- Miller, G. A. (1995). Wordnet: a lexical database for english. *Communications of the ACM*, 38(11):39–41.
- Nakashole, N., Weikum, G., and Suchanek, F. (2012). Patty: A taxonomy of relational patterns with semantic types. In *Proceedings of the 2012 Joint Conference on Empirical Methods in Natural Language Processing and Computational Natural Language Learning*, pages 1135–1145.
- Panchenko, A., Faralli, S., Ruppert, E., Remus, S., Naets, H., Fairon, C., Ponzetto, S. P., and Biemann, C. (2016). Taxi at semeval-2016 task 13: a taxonomy induction method based on lexico-syntactic patterns, substrings and focused crawling. In *Proceedings of the 10th International Workshop on Semantic Evaluation (SemEval-2016)*, pages 1320–1327.
- Shang, C., Dash, S., Chowdhury, M. F. M., Mihindukulasooriya, N., and Gliozzo, A. (2020). Taxonomy construction of unseen domains via graph-based cross-domain knowledge transfer. In *Proceedings of the 58th annual meeting of the Association for Computational Linguistics*, pages 2198–2208.
- Snow, R., Jurafsky, D., and Ng, A. (2004). Learning syntactic patterns for automatic hypernym discovery. *Advances in neural information processing systems*, 17.
- Sun, T.-X., Liu, X.-Y., Qiu, X.-P., and Huang, X.-J. (2022). Paradigm shift in natural language processing. *Machine Intelligence Research*, 19(3):169–183.
- Tan, L., Bond, F., and van Genabith, J. (2016). Usaar at semeval-2016 task 13: Hyponym endocentricity. In *Proceedings of the 10th International Workshop on Semantic Evaluation (SemEval-2016)*, pages 1303–1309.
- Torregrossa, F., Allesiardo, R., Claveau, V., and Gravier, G. (2021). Unsupervised tree extraction in embedding spaces for taxonomy induction. In *IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology*, pages 302–309.
- Wang, S., Zhao, R., Chen, X., Zheng, Y., and Liu, B. (2021). Enquire one’s parent and child before decision: Fully exploit hierarchical structure for self-supervised taxonomy expansion. In *Proceedings of the Web Conference 2021*, pages 3291–3304.
- Wang, S., Zhao, R., Zheng, Y., and Liu, B. (2022). Qen: Applicable taxonomy completion via evaluating full taxonomic relations. In *Proceedings of the ACM Web Conference 2022*, pages 1008–1017.
- Williams, R. J. (1992). Simple statistical gradient-following algorithms for connectionist reinforcement learning. *Reinforcement learning*, pages 5–32.
- Yang, H.-R. and Ni, W. (2022). Continuous-time distributed heavy-ball algorithm for distributed convex optimization over undirected and directed graphs. *Machine Intelligence Research*, 19(1):75–88.
- Yang, S., Zou, L., Wang, Z., Yan, J., and Wen, J.-R. (2017). Efficiently answering technical questions—a knowledge graph approach. In *Proceedings of the AAAI Conference on Artificial Intelligence*, volume 31.
- Zhang, J., Song, X., Zeng, Y., Chen, J., Shen, J., Mao, Y., and Li, L. (2021). Taxonomy completion via triplet matching network. In *Proceedings of the AAAI Conference on Artificial Intelligence*, volume 35, pages 4662–4670.