

一种神经范畴标注模型^{*}

吴惠甲^{1,3}, 张家俊^{1,3}, 宗成庆^{1,2,3}



¹(模式识别国家重点实验室(中国科学院 自动化研究所),北京 100190)

²(中国科学院 脑科学与智能技术卓越创新中心,北京 100190)

³(中国科学院大学,北京 100190)

通讯作者: 吴惠甲, E-mail: huijia.wu@ia.ac.cn

摘要: 范畴标注是组合范畴语法解析中的子任务之一,可用于提高解析器的效率和性能。传统的最大熵模型需要手工定义特征模板,神经网络则通过隐含层学习到离散特征的分布式表示,从而自动提取分类需要的特征。引入该模型来解决该问题,在原有神经语言模型的基础上加入了向量化的词性表示层和范畴表示层,并通过反向传播自动更新词向量、词性向量和范畴向量,学习到它们的分布式表示。此外,在预测时采用束搜索的序列解码方式来引入标签之间的依赖信息。实验结果表明,这两种改进都能提升模型的性能,使其在范畴标注任务上比传统的最大熵模型效果要好(提升 1%)。

关键词: 范畴标注;分布式表示;神经语言模型;束搜索

中图法分类号: TP18

中文引用格式: 吴惠甲,张家俊,宗成庆.一种神经范畴标注模型.软件学报,2016,27(11):2691–2700. <http://www.jos.org.cn/1000-9825/4873.htm>

英文引用格式: Wu HJ, Zhang JJ, Zong CQ. Neural-Based combinatory categorial grammar supertagging. Ruan Jian Xue Bao/Journal of Software, 2016,27(11):2691–2700 (in Chinese). <http://www.jos.org.cn/1000-9825/4873.htm>

Neural-Based Combinatory Categorical Grammar Supertagging

WU Hui-Jia^{1,3}, ZHANG Jia-Jun^{1,3}, ZONG Cheng-Qing^{1,2,3}

¹(National Laboratory of Pattern Recognition (Institute of Automation, The Chinese Academy of Sciences), Beijing 100190, China)

²(Center for Excellence in Brain Science and Intelligence Technology, The Chinese Academy of Sciences, Beijing 100190, China)

³(University of Chinese Academy of Sciences, Beijing 100190, China)

Abstract: As a sub-task for combinatory categorial grammar (CCG) based parsing, categorical tagging can improve parsing efficiency and accuracy. While traditional maximum entropy model solves this problem by designing meaningful feature templates, neural network can extract features automatically based on distributed representations. This paper proposes a neural categorical tagging model with two improvements. First, word embedding layer is extended with a part-of-speech embedding layer and a category embedding layer, which facilitates learning their distributed representations jointly by the back-propagation algorithm. Secondly, a beam search is used in the decoding to capture the dependencies among tags. These two improvements make the proposed model more accurate than the state-of-art maximum entropy based tagger (up to 1%).

Key words: categorical tagging; distributed representation; neural language model; beam search

组合范畴语法(combinatory categorial grammar,简称 CCG)是一种类型驱动的词汇化语法,该语法能够精确

* 基金项目: 国家自然科学基金(61333018); 中国科学院战略性先导科技专项(XDB02070007)

Foundation item: National Natural Science Foundation of China (61333018); Strategic Priority Research Program of the Chinese Academy of Sciences (XDB02070007)

收稿时间: 2015-03-17; 修改时间: 2015-06-24; 采用时间: 2015-07-28

地定位每个词的范畴,从而挖掘出一个句子的深层依赖关系,如谓词论元关系、概念复合关系、事件组合关系等^[1].自动范畴标注是设计组合范畴语法解析器时面临的一个重要问题,目的是给句子里的每个词打上范畴标签,从而提高解析器的性能^[2].该问题类似于词性标注问题,其区别在于,词性标注的标签数目只有几十种,并且彼此代表独立的语法成分,但范畴标签数目有近千种,并且标签之间有很强的依赖关系^[3].

在解决范畴标注问题上,采用的方法与词性标注类似.其中有基于最大熵模型的范畴标注^[4,5],该模型定义了词和范畴的特征模板,而且用到词性信息来丰富标签知识.但需要手工设计特征模板,模板定义的好坏在很大程度上影响了模型性能的优劣,使得其泛化性能较差.此外,该模型是把句子的每个词隔离开来,单独进行标注.但在组合范畴语法中,一个词近邻的范畴标签在很大程度上决定了自身的范畴类别,把词与词独立地进行预测是不合适的.

一个很自然的想法就是用序列标注模型,因为序列标注模型(如最大熵模型)比点预测模型考虑的信息要丰富.但在实际应用中,由于标签类别过多导致数据稀疏性严重以及计算复杂度过高的问题.这方面的工作主要有基于弱监督隐马尔可夫模型的范畴标注模型^[6,7],其特点在于该模型转移矩阵的设计是基于词汇表中范畴的分布以及组合范畴语法规则的.但该模型报告的效果不好,究其原因可能是范畴标签的区分度不明显,想要预测准确需要更多的监督信息.

基于上述分析,我们认为,如果既能利用最大熵模型灵活选取特征的特点,又能类似于序列标注模型那样考虑全局信息,必定可以取得较好的效果.因此,我们选用神经语言模型作为解决范畴标注问题的方法.这方面的工作主要有文献[8],我们和该文献工作的区别主要有两点:首先是我们用到了词性向量作为区分特征;其次是在解码过程采用束搜索的方式,利用上一个词的标签信息循环地解码.前者表明词性向量对范畴标注是有很大帮助的,后者的好处在于能够利用标签之间的依赖关系信息,从而提高模型性能.

1 组合范畴语法和范畴标注

组合范畴语法是自然语言语义解析的重要组成部分.语义解析分为语义表示、语义推断和语义学习这3个部分,其中与组合范畴语法相关的是语义表示.它主要回答两个问题:一是如何用形式化的符号来表示自然语言,二是如何定义符号之间的运算来表示语言单元之间的关联性.因此,研究组合范畴语法对语义理解起到至关重要的作用.

范畴标注就是给定一个句子作为输入,输出为该句子中每个词的范畴标签.由于组合范畴语法的解析较依赖于词汇的范畴类型,因此,一个准确的范畴标注工具对范畴语法解析有很大帮助^[9].此外,范畴标注可以筛选出有可能的范畴候选集合,在很大程度上影响解析器性能^[10].

1.1 组合范畴语法

范畴语法是一种词汇化语法,该语法把语法单元定义为一个范畴,也称为类型,并通过一些组合规则把小的语法单元组合成更大的语法单元,最后组合成一个完整的句子.小的语法单元比如词,更大的可以是短语、子句或整句.范畴和组合规则一起构成了范畴语法.

组合范畴语法是范畴语法的一种,在原有组合规则上做了一些扩展,增加了函数复合、类型提升规则.该语法所定义的范畴集合 C 如下^[11]:

- (1) 原子范畴集合,包括 $S, NP, N, PP \in C$.
- (2) 函数范畴集合:如果 $X, Y \in C$,那么 $X/Y \in C, XY \in C$.

在上述定义中, X/Y 是函数范畴,表明其可以向右结合一个范畴 Y ,返回一个范畴 X ,其中的“/”表示结合的方向(向右),类似地,反斜杠“\”表示向左结合.比如,我们有如下的范畴组合形式:

$$\left\{ \begin{array}{l} \text{基本} := NP / NP \\ \text{内容} := NP \\ \text{基本: } NP / NP \text{ 内容: } NP \Rightarrow \text{基本内容: } NP \\ \text{基本内容: } NP \end{array} \right. \quad (1)$$

在公式(1)中,“基本”一词的范畴类型为 NP / NP ,表明该词可以向右结合一个名词短语 NP (内容),根据某种规则得到一个 NP (基本内容).这里所说的规则就是指组合范畴语法中定义的一套规则,即前向应用和后向应用规则,形式化表示如下:

- a. 前向应用规则: $X/Y:f Y:a \Rightarrow X:f(a)$.
- b. 后向应用规则: $Y:a X/Y:f \Rightarrow X:f(a)$.

上述规则可直观地解释为: X/Y 看做一个映射,这个映射把实例化之后的 $Y:a$ 映成范畴 $X:f(a)$.此外,组合范畴语法还定义了其他两种规则,即函数复合规则和类型提升规则,具体如下:

- c. 前向复合规则: $X/Y:f Y/Z:g \Rightarrow_B X/Z:\lambda x.f(g(x))$.
- d. 后向复合规则: $Y/Z:g X/Y:f \Rightarrow_B X/Z:\lambda x.f(g(x))$.
- e. 前向类型提升规则: $X:a \Rightarrow_T T/(T/X):\lambda f.f(a)$.
- f. 后向类型提升规则: $X:a \Rightarrow_T T/(T/X):\lambda f.f(a)$.

值得注意的是,在类型提升规则中,原子范畴 X 通过类型提升为函子范畴 $T(T/X)$,这里的 X 不可以是函子范畴类型^[1].

1.2 范畴标注

根据上节我们对组合范畴语法的描述,范畴标注的任务就是给句子中的每个词打上合适的范畴标签,这些标签可以是原子类型,也可以是较复杂的函子类型.给定一个句子中每个词的范畴,我们可以根据范畴组合规则把这些范畴自底向上两两组合起来,直至生成一个树.比如,我们有如图 1 所示的范畴树.该范畴树可以根据句子中的每个词的范畴得到,即,我们并不需要定义层次化的树结构,只需定义范畴序列即可.当然,树结构会比序列结构包含更多的信息.由于我们的训练数据来自于 CCG 树库^[11],因此,如何充分利用树结构信息来设计分类模型就是我们考虑的重点.

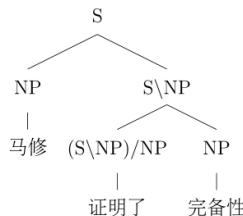


Fig.1 A CCG derivation tree

图 1 组合范畴语法解析树

Clark 和 Curran 提出的范畴标注模型^[4]是基于最大熵模型的,该模型的结构如下:

$$p(c | h) = \frac{1}{Z(h)} \exp \left[\sum_i \lambda_i f_i(c, h) \right] \quad (2)$$

该模型定义了在给定上下文信息 h 的条件下范畴 c 的概率分布,其中, $f_i(c, h)$ 为从这对 (c, h) 中抽取的第 i 维特征,定义为

$$f_j(c, h) = \begin{cases} 1, & \text{如果当前词是 the 且 } c(\text{the}) = NP / N \\ 0, & \text{otherwise} \end{cases} \quad (3)$$

公式(3)表明:如果某个词是 the,对应的标签是 NP / N ,那么这条规则成立;反之,则不成立.

该模型存在的问题是,最大熵模型只能挖掘局部的上下文信息.具体来说,就是在范畴 c 的不确定性完全由

上下文信息 h 所控制, 这显然是不合理的. 假若我们有两个范畴 c_1, c_2 , 彼此之间互相关联, 但在 c_1, c_2 都未知的前提下, h_1 是不可能包含任何关于 c_2 的信息的. 这就是点预测模型的不足之处.

序列预测模型能够解决这种不足, 相关的工作主要是基于半监督隐马尔可夫模型的范畴标注^[6], 模型的生成过程为

$$\left. \begin{array}{l} \text{先验分布:} \\ \phi_t \sim \text{Dirichlet}(\alpha_\phi, \phi_t^0), \forall t \in T \\ \pi_t \sim \text{Dirichlet}(\alpha_\pi, \pi_t^0), \forall t \in T \\ \text{第 } i \text{ 个标签的生成过程:} \\ x_i | y_i \sim \text{Categorical}(\phi_{y_i}) \\ y_{i+1} | y_i \sim \text{Categorical}(\pi_{y_i}) \end{array} \right\} \quad (4)$$

该模型同样也存在一些问题: 首先, 范畴标签数目过多, 导致 π_t 维度很高, 解码时复杂度会很高; 其次, 用转移矩阵 $y_{i+1}|y_i$ 来描述范畴与范畴之间的联系是不恰当的, 因为畴之间的组合主要是根据语法定义的规则, 而并非根据最大似然估计得到的离散分布; 再者, 本来多标签预测因为监督信息不足会导致准确率低, 再用半监督去做就会使得原本稀有的监督信息缺失, 进一步降低性能.

神经语言模型类似于最大熵模型, 也是通过上下文来预测当前词的标签, 其区别在于利用嵌入层把特征抽象为一种分布式的表示, 这种连续型表示可看做是一种“软”表示, 相对于最大熵模型离散化的“硬”表示, 优势在于能够泛化一些外来词和低频词. 此外, 神经网络可设置多个隐含层, 对输入进行不同水平的抽象, 也可看做是一个深层的最大熵模型. 其好处在于不需要手工定义特征模板, 能够通过隐含层自动学习到特征的抽象表示. 此外, 还可提供类似于序列模型的解码功能以及灵活设置输入、输出的特点. 具体实施细节将在下一节详细介绍.

2 神经范畴标注模型

在自然语言处理应用中, 词是处理的基本单元, 如何表示词也是一个基本问题. 从基于词频、共现矩阵分解的潜在语义分析(latent semantic analysis, 简称 LSA)^[12]、基于概率矩阵分解的潜在语义分析(probabilistic latent semantic analysis, 简称 PLSA)^[13]、主题模型(latent dirichlet allocation, 简称 LDA)^[14]到基于词表示的神经网络模型^[15-18], 以及近年提出的全局向量表示^[19,20], 词的表示越来越细致.

我们扩展词向量的思想, 提出了一种基于词性向量和范畴向量的范畴标注预测模型. 该模型基于 Bengio 等人^[15]提出的神经语言模型, 目的是希望网络的输出与目标尽可能地接近, 其度量采用如下的交叉熵损失函数:

$$\ln P(t^i | \mathbf{x}_{ct}^i, \mathbf{p}_{ct}^i, \mathbf{c}_{ct}^{-i}, \mathbf{w}) = \sum_{k=1}^K t_k^i \ln y_k^i \quad (5)$$

其中,

- $t^i \in \{(t_1^i, \dots, t_K^i) | t_k^i = 1, t_{-k}^i = 0, k \in \{1, 2, \dots, K\}\}$ 表示当前第 i 个词的标签分布, 即, 若当前词的真实标签是 k , 则有 $t_k^i = 1, t_{-k}^i = 0$;
- \mathbf{x}_{ct}^i 表示在窗口 ct 下所取的词向量集合;
- \mathbf{p}_{ct}^i 表示在窗口下的词性向量集合;
- \mathbf{c}_{ct}^{-i} 表示在窗口下除去标签 i 位置的范畴向量集合.

比如, 我们可以取 $\mathbf{x}_{ct}^i := \{x_i, x_{i+1}\}$, $\mathbf{p}_{ct}^i := \{p_i, p_{i+1}\}$, $\mathbf{c}_{ct}^{-i} := \{c_{i+1}\}$, 这意味着用当前词、当前词的词性、下一个词及其词性和下一个范畴来预测当前词的范畴. 为了简化标记, 我们用 $\mathbf{x}, \mathbf{p}, \mathbf{c}_{-i}$ 来替代 $\mathbf{x}_{ct}^i, \mathbf{p}_{ct}^i$ 和 \mathbf{c}_{ct}^{-i} , $y_k^i := y_k(\mathbf{x}, \mathbf{p}, \mathbf{c}_{-i}, \mathbf{w})$ 为神经网络的输出, 其中, \mathbf{w} 为网络的参数集合. 我们以两层感知机模型为例:

$$y_k(\mathbf{x}, \mathbf{p}, \mathbf{c}_{-i}, \mathbf{w}) = \frac{\exp[f_k(\mathbf{x}, \mathbf{p}, \mathbf{c}_{-i}, \mathbf{w})]}{\sum_{k'} \exp[f_{k'}(\mathbf{x}, \mathbf{p}, \mathbf{c}_{-i}, \mathbf{w})]} \quad (6)$$

其中, $f_k(\mathbf{x}, \mathbf{p}, \mathbf{c}_{-i}, \mathbf{w})$ 为输出层第 k 个神经元的输入. 因而,

$$f_k(\mathbf{x}, \mathbf{p}, \mathbf{c}_{-i}, \mathbf{w}) = b_k^o + \sum_j w_{kj}^o \sigma(z_j^h) \quad (7)$$

其中, b_k^o 表示输出层第 k 个节点的偏置, w_{kj}^o 表示隐含层第 j 个节点到输出层第 k 个节点的权重, z_j^h 是隐含层第 j 个节点的输入. 同时, 我们有,

$$z_j^h = b_j^h + \sum_i u_{ji}^h x_i + \sum_t v_{jt}^h p_t + \sum_l w_{jl}^h c_l \quad (8)$$

其中, u_{ji}^h 表示词向量层第 i 个神经元到隐含层第 j 个神经元的权重; v_{jt}^h 是词性向量层第 t 个神经元到隐含层第 j 个神经元的权重; w_{jl}^h 是范畴向量层第 l 个神经元到隐含层第 j 个神经元的权重; b_j^h 表示隐含层第 j 个神经元的偏置; x_i, p_t, c_l 分别为词向量、词性向量和范畴向量的第 i 维、第 t 维和第 l 维.

2.1 训 练

我们的训练数据集由 L 个句子组成, 设每个句子的长度为 $n^l, l=1, \dots, L$, 我们可以抽取到如下的训练数据:

$$\mathcal{D} = \{\mathbf{x}_i^l, \mathbf{p}_i^l, \mathbf{c}_{-i}^l, t_i^l\}_{i=1}^{n^l}, l=1, \dots, L.$$

其中, $\mathbf{x}_i^l, \mathbf{p}_i^l, \mathbf{c}_{-i}^l$ 作为输入, t_i^l 为预测标签. 训练的目标是最小化公式(5)的误差函数. 可以通过反向传播算法来更新网络权重 $\mathbf{w} = \{\mathbf{b}^h, \mathbf{w}^h, \mathbf{b}^o, \mathbf{w}^o\}$ 、词向量 \mathbf{x} 、词性向量 \mathbf{p} 以及范畴向量 \mathbf{c}_{-i} , 更新过程如算法 1 所示.

算法 1. 范畴标注模型的训练过程(第 i 个词, 学习率为 ε).

(1) 前馈过程

- (a) 把第 i 个词的 word_{ct} 特征、上下文词性 pos_{ct} 和上下文范畴 cat_{ct} 分别通过映射表 T 映射为范畴向量和词向量: $\mathbf{x} \leftarrow T(\text{word}_{ct}), \mathbf{p} \leftarrow T(\text{pos}_{ct}), \mathbf{c} \leftarrow T(\text{cat}_{ct})$.
- (b) 计算隐含层的输入、输出: $\mathbf{z}^h \leftarrow \mathbf{b}^h + \mathbf{U}^h \mathbf{x} + \mathbf{V}^h \mathbf{p} + \mathbf{W}^h \mathbf{c}, \mathbf{a}^h \leftarrow \sigma(\mathbf{z}^h)$.
- (c) 计算输出层的输入、输出: $\mathbf{f} \leftarrow \mathbf{b}^o + \mathbf{W}^o \mathbf{a}^h, \mathbf{y} \leftarrow \text{softmax}(\mathbf{f})$.
- (d) 计算输出与真实值的误差: $C = \ln P(\mathbf{D} | \mathbf{w})$.

(2) 误差反传过程

- (a) 计算输出层残差: $\delta^o \leftarrow \nabla_f C \cdot \sigma'(z^o)$ 、隐含层残差 $\delta^h = \mathbf{W}^{oT} \delta^o \cdot \sigma'(z^h)$.
- (b) 更新隐含层到输出层的权重: $\mathbf{W}^o \leftarrow \mathbf{W}^o - \varepsilon \mathbf{a}^h \delta^o, \mathbf{b}^o \leftarrow \mathbf{b}^o - \varepsilon \delta^o$.
- (c) 更新嵌入层到隐含层的权重: $\mathbf{U}^h \leftarrow \mathbf{U}^h - \varepsilon \mathbf{x} \delta^h, \mathbf{V}^h \leftarrow \mathbf{V}^h - \varepsilon \mathbf{p} \delta^h, \mathbf{W}^h \leftarrow \mathbf{W}^h - \varepsilon \mathbf{c} \delta^h$.
- (d) 更新词向量、词性向量和范畴向量: $\mathbf{x} \leftarrow \mathbf{x} - \varepsilon \delta^h \mathbf{V}^{hT}, \mathbf{p} \leftarrow \mathbf{p} - \varepsilon \delta^h \mathbf{U}^{hT}, \mathbf{c} \leftarrow \mathbf{c} - \varepsilon \delta^h \mathbf{W}^{hT}$.

2.2 预 测

传统的预测方法是: 在训练好神经网络之后, 通过前馈传播得到网络的输出 $\mathbf{y}(\mathbf{x}, \mathbf{p}, \mathbf{c}_{-i}, \mathbf{w})$, 再取 n -best 作为标签 t_i 的预测结果. 但在范畴标注任务中, 我们是对整句话打上范畴标签, 因而在预测当前词的时候, 需要知道它的历史范畴标签. 在测试数据集中, 这种标签我们是不知道的, 因此, 我们需要从句子的一端开始, 通过束搜索^[21,22]的方式不断解码, 并把前一个词的标注结果当作特征加入到预测当前词的输入中, 标注过程如图 2 所示.

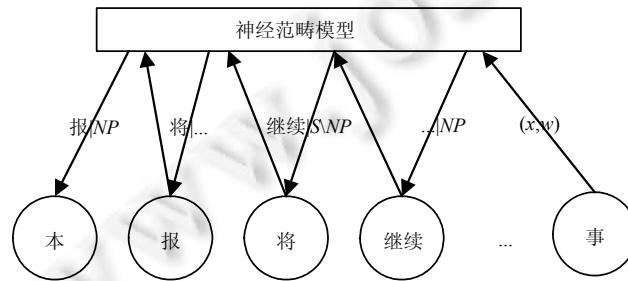


Fig.2 Sequential decoding in neural categorical model, beginning at the last word ‘事’

图 2 神经范畴模型的序列预测, 从句尾词“事”向前逐个预测

这样,整个句子通过循环解码方式就能得到其中每个词的标签,形式化表示为

$$P(\mathbf{c} | \mathbf{x}, \mathbf{p}, \mathbf{w}) = \prod_{i=n}^1 P(c_i | \mathbf{x}_i, \mathbf{p}_i, \hat{c}_{i+1}, \mathbf{w}) \quad (9)$$

其中, \hat{c}_{-i} 表示的是 c_{-i} 的预测值,束搜索的宽度设置为 1. 我们也可以选用从前往后解码的方式,其效果是类似的. 在实验中,选择从后往前解码的原因是,在训练数据集中,最后一个词是 NP 的频率比较大,由于对 NP 的识别是很准确的,因此,基于 NP 再预测前一个词的范畴也较为可靠.

2.3 预训练

之前的词向量、词性向量和范畴向量都是随机初始化的,针对范畴标注训练语料稀缺的问题,我们可以利用大量无监督文本信息预训练得到这些向量的初始化值,以加入到模型中. 对于词向量而言,能够利用大量无标注数据学习到词的分布式表示(distributed representation);对于词性向量和范畴向量而言,通过预训练能够达到类似于规则的效果.

由于预训练这些向量的过程类似,这里,我们只讨论范畴向量的预训练. 我们希望预训练之后的范畴向量能够体现范畴中的相互依赖关系,从而有效去除范畴之间的关联信息. 下面我们着重介绍如何训练范畴向量.

根据第 1 节的介绍我们知道,范畴之间可以通过应用、复合等方式进行组合. 我们希望通过预训练来体现诸如 $(X/Y, Y, X)$ 这 3 种标签之间的内在联系,即我们希望有:

$$P(X|(X/Y, Y))=1 \quad (10)$$

上式反映了 $X/Y \Rightarrow X$ 的组合规则. 通过预训练范畴表示,我们也希望我们的网络能够模拟出这些规则,即,输入 X/Y 和 Y ,输出为 X . 为此,我们从组合范畴语法解析树中抽取出这些训练数据,用特定的神经网络来训练得到范畴向量,形式化表示为

$$\ln P(\mathbf{t}^p | c_l, c_r) = \sum_{k=1}^K t_k^p \ln y_k^p \quad (11)$$

其中, \mathbf{t}^p 表示给定左范畴 c_l 和右范畴 c_r 之后的组合范畴分布. 在以上例子中, 我们有 $c_l := X/Y, c_r := Y$ 和 $t_k^p := X$. 值得注意的是,这里的 c_l 和 c_r 都是范畴的分布式表示. 我们通过神经网络学习到这种表示,用作范畴向量的初始化. 学习过程与范畴标注模型是类似的. 此外,在上式中, \mathbf{t}^p 表示 c_l, c_r 通过规则(11)组合之后的概率分布. 通过对该网络进行训练,我们就能学习到范畴的分布式表示,而这种分布式表示暗含了标签之间的依赖关系.

3 实验**

为了评价模型的性能,我们采用的训练语料有两类:一类是中文的清华 CCG 树库^[23,24],另一类是英文的 CCG Bank 语料^[11]. 由于中文语料库没有词性标签,我们利用斯坦福词性标注器^[25]对该语料库进行词性标注后使用. 我们把训练数据分为 10 份,其中,8 份用作训练,1 份用于开发集调参,1 份用于测试. 在英文语料库上,我们采用标准划分^[11],选择 wsj02-21 作为训练数据,wsj00 用作调参,wsj23 用作测试. 这两类语料训练集的统计指标见表 1.

Table 1 Statistics for the used training corpora

表 1 训练语料库的统计数据

	解析树数目	范畴数目	词性数目	词汇数目
中文语料库	6 557	735	32	17 631
英文语料库	36 904	1 286	49	44 209

3.1 模型性能比较

在实验对比上,我们选择了 3 种模型:其一是 Clark 和 Curran(C&C)模型^[4],该模型是开源的,在语料库上经重新训练使用;其二是 NLTK 的 ME 工具包^[25],该工具包原本是作词性标注的,我们将其移植到该范畴标注问题上;

** 模型代码和测试脚本地址:<https://github.com/fishiwhj/Neural-Category-Tagging-Model>

其三是 Lewis 和 Steedman(L&C)的结果^[8].

在参数选择上,词向量和词性向量窗口大小都为 6,范畴向量窗口大小为 1.词向量为 150 维,词性向量为 50 维,范畴向量为 100 维,隐含层节点数为 300.束搜索的宽度为 1.我们分别对词汇、词性和范畴进行了预训练,其中,词汇的预训练我们采用 Collobert 等人方法^[16],词性和范畴的预训练见第 2.3 节.

Table 2 Comparing the accuracies of several categorical tagging models

表 2 几种模型的范畴标注性能对比

	汉语准确率(%)	英语准确率(%)
C&C	80.2	91.5
NLTK ME	75.35	85.28
L&S	-	91.3
NCT(Point)	82.33	92.26
NCT(Beam)	82.52	92.51

在表 2 中,NCT(Point)是在解码的时候不考虑上一个词的标签的模型,结构与 L&S 是类似的.区别是加入了词性表示层和预训练的词向量、词性向量和范畴向量.NCT(Beam)是在上一个模型基础上加入束搜索后的模型,从结果可以看出,加入范畴标签的信息对分类性能是有帮助的.

3.2 预训练

由于嵌入层的预训练对模型性能有很大影响,我们比较了词汇预训练、词性预训练和范畴预训练的组合对模型性能的影响,见表 3.

Table 3 Comparison of NCT models with different pre-trainings: words, part-of-speeches and categories

表 3 词汇预训练、词性预训练和范畴预训练对范畴标注模型性能的影响

	汉语准确率(%)	英语准确率(%)
NCT(random)	81.53	91.52
NCT+PretW	82.15	92.12
NCT+PretWP	82.19	92.2
NCT+PretWC	82.36	92.37
NCT+PretWPC	82.52	92.51

在表 3 中,NCT(random)表示随机初始化的范畴标注模型,初始化分布用的是均值为 0,方差为 0.01 的正态分布.NCT+PretW 表明加入预训练词向量后的模型,其余的两种嵌入向量则随机初始化.类似地,NCT+PretWPC 是把词、词性和范畴全部通过预训练进行初始化之后的模型.它们预训练方法见上一节.从结果可以看出,预训练嵌入向量对模型性能的提升有很大的帮助.特别地,词性向量和范畴向量的预训练也会提升性能,表明预训练得到的嵌入表示要优于随机初始化表示.

3.3 分布式表示维度的影响

由于我们用分布式表示来编码词、词性和范畴单元,不同维度就决定了表示能力的强弱.显然,如果表示维度过低,就会造成神经网络所抽取的特征过少,从而不能完整地表示要区分的对象;相反,如果维度过高,也会造成多个神经元的功能冗余,增加不必要的计算量.

在表 4 中,实验语料为英文的 CCG Bank,窗口大小固定为 6.可以看出,词向量、词性向量和范畴向量维度分别为 150,50 和 100 时效果最好.直观上看,类别数目越多,所要表示该类别的特征数就越多,相应的维度就越大.

Table 4 Comparison of the models with different embedding sizes

表 4 不同分布式表示维度下模型性能的比较

词汇	词性	范畴	范畴准确率(%)
50	50	50	89.62
100	50	50	91.37
150	50	100	92.26
200	200	250	92.21

3.4 窗口大小的影响

由于我们是通过开窗口来确定上下文,因此,窗口的大小对模型性能影响是很大的.表 5 列出了不同窗口大小的影响,我们的实验数据集为英文 CCG Bank,固定词向量、词性向量和范畴向量维度分别为 150,50 和 100.

Table 5 Comparison of the models with different window sizes

表 5 不同特征窗口大小下模型性能的比较

词汇/词性	范畴	范畴准确率(%)
2	1	90.35
4	1	91.69
6	1	92.26
8	1	92.23

表 5 表明,在词汇和词性窗口大小为 6、范畴窗口大小为 1 时效果最好,增加和减小窗口都会使得性能下降.原因可能是,窗口开得过小,会导致有些对分类有用的特征没有包含进来;窗口开得过大则会引入噪声,导致分类准确率下降.

3.5 预训练范畴向量分析

从表 3 中,我们可以观察到预训练范畴向量对模型性能的影响.配置信息与上一节实验是类似的,只不过这里只考虑范畴向量.我们也分别在中文和英文两个语料库上做了实验,我们分别从这两个树库上抽取所需要的训练数据集.在中文上我们抽取了 456 947 个范畴对作为训练语料,英文上抽取了 1 102 975 个范畴对作为训练语料.实验设计为:给定两个能够组合的范畴作为输入,检验网络输出是否与组合规则输出一致.实验结果见表 6.

Table 6 Accuracies of categorical compositions using pre-trained embeddings

表 6 预训练范畴向量模拟规则的准确率

组合规则	汉语准确率(%)	英语准确率(%)
前向应用(>)	99.17	99.85
后向应用(<)	98.83	98.28
前向复合(>B)	98.67	99.63
后向复合(<B)	98.25	99.59

表 6 的实验结果说明,预训练后的范畴向量确实能够反映出范畴对三者之间的关系.因此,通过预训练之后得到的范畴表示比随机初始化的表示效果要好.此外,该实验结果还表明,利用神经网络可以学习到类似于规则的知识.这一点也反映了神经网络较灵活的特性,可以模拟一些基于规则的模型.

3.6 错误分析

训练好的范畴标注模型在不同数据集上表现出不同的效果:

- 在汉语中,大多容易把 NP 和 $S\backslash NP$ 混淆.经分析得知,这些范畴为 $S\backslash NP$ 的词,有时候在句中也表现为 NP ,比如总结($S\backslash NP$)经验教训和工作总结(NP)、积累($S\backslash NP$)经验和财富的积累(NP)等.或许在汉语中, NP 和 $S\backslash NP$ 的界限不是那么严谨.
- 在英语中,容易把($S\backslash NP$)/($S\backslash NP$)误识别为($S\backslash NP$)/ NP ,前者一般是助动词或系动词,后者一般为及物动词.由于助动词或系动词有的时候也具有范畴($S\backslash NP$)/ NP ,因此,把它们区分开来可能需要借助更多的信息,比如在句子中的位置等.

4 总结和展望

神经网络能够通过隐含层来分布式表示词汇、词性和范畴特征,避免了手工定义特征模板的工作.通过拼接词向量层、词性向量层和范畴向量层来作为输入特征,并通过反向传播算法学习到词、词性和范畴的分布式表示,并把预训练得到的词向量、词性向量和范畴向量加入到模型中,可以提升模型的泛化能力.此外,在解码过程中利用束搜索的思想,能够利用上一个词的标签信息,循环地进行解码.

预训练范畴向量只考虑了函数应用和函数复合规则,类型提升规则并没有考虑。以后可加入对该规则的模拟。在模型上,我们相当于一个两层感知机模型,或许可以利用贝叶斯神经网络模型,针对组合范畴语法的特点设计合适的先验。最后,范畴标注主要是为了解析器服务的,也可以把工作进一步扩展到组合范畴语法的解析器上,比如考虑如何利用神经网络设计解析器。

致谢 感谢清华大学信息技术研究院的周强老师给予的支持与建议。

References:

- [1] Steedman M, Baldridge J. Combinatory categorial grammar. In: Non-Transformational Syntax: Formal and Explicit Models of Grammar. Wiley-Blackwell, 2011. [doi: 10.1002/9781444395037.ch5]
- [2] Clark S, Curran JR. The importance of supertagging for wide-coverage CCG parsing. In: Proc. of the 20th Int'l Conf. on Computational Linguistics. Association for Computational Linguistics, 2004. 282–288. [doi: 10.3115/1220355.1220396]
- [3] Steedman M. The Syntactic Process. Cambridge: MIT Press, 2000.
- [4] Clark S, Curran JR. Wide-Coverage efficient statistical parsing with CCG and log-linear models. Computational Linguistics, 2007, 33(4):493–552. [doi: 10.1162/coli.2007.33.4.493]
- [5] Auli M, Lopez A. Training a log-linear parser with loss functions via softmax-margin. In: Proc. of the Conf. on Empirical Methods in Natural Language Processing. Association for Computational Linguistics, 2011. 333–343.
- [6] Baldridge J. Weakly supervised supertagging with grammar-informed initialization. In: Proc. of the 22nd Int'l Conf. on Computational Linguistics, Vol.1. Association for Computational Linguistics, 2008. 57–64.
- [7] Garrette D, Dyer C, Baldridge J, Smith NA. Weakly-Supervised Bayesian learning of a CCG supertagger. In: Proc. of the CoNLL. 2014.
- [8] Lewis M, Steedman M. Improved CCG parsing with Semi-supervised Supertagging. Trans. of the Association for Computational Linguistics, 2014,2:327–338.
- [9] Bangalore S, Joshi AK. Supertagging: An approach to almost parsing. Computational Linguistics, 1999,25(2):237–265.
- [10] Curran JR, Clark S, Vadas D. Multi-Tagging for lexicalized-grammar parsing. In: Proc. of the 21st Int'l Conf. on Computational Linguistics and the 44th Annual Meeting of the Association for Computational Linguistics. Association for Computational Linguistics, 2006. 697–704. [doi: 10.3115/1220175.1220263]
- [11] Hockenmaier J, Steedman M. CCGbank: A corpus of CCG derivations and dependency structures extracted from the Penn Treebank. Computational Linguistics, 2007,33(3):355–396. [doi: 10.1162/coli.2007.33.3.355]
- [12] Deerwester SC, Dumais ST, Landauer TK, Harshman R. Indexing by latent semantic analysis. Journal of the American Society for Information Science, 1990,41(6):391–407. [doi: 10.1002/ (SICI)1097-4571(199009)41:6<391::AID-ASI1>3.0.CO;2-9]
- [13] Hofmann T. Unsupervised learning by probabilistic latent semantic analysis. Machine Learning, 2001,42(1-2):177–196. [doi: 10.1023/A:1007617005950]
- [14] Blei DM, Ng AY, Jordan MI. Latent dirichlet allocation. Journal of Machine Learning Research, 2003,3:993–1022.
- [15] Bengio Y, Ducharme R, Vincent P, Jauvin C. A neural probabilistic language model. Journal of Machine Learning Research, 2003,3: 1137–1155.
- [16] Collobert R, Weston J, Bottou L, Karlen M, Kavukcuoglu K, Kuksa P. Natural language processing (almost) from scratch. The Journal of Machine Learning Research, 2011,12:2493–2537.
- [17] Mnih A, Hinton G. Three new graphical models for statistical language modelling. In: Proc. of the 24th Int'l Conf. on Machine Learning. ACM Press, 2007. 641–648. [doi: 10.1145/1273496.1273577]
- [18] Mikolov T, Karafiat M, Burget L, Cernocký J, Khudanpur S. Recurrent neural network based language model. In: Proc. of the 11th Annual Conf. of the Int'l Speech Communication Association (INTERSPEECH 2010). Makuhari, 2010. 1045–1048.
- [19] Huang EH, Socher R, Manning CD, Ng AY. Improving word representations via global context and multiple word prototypes. In: Proc. of the 50th Annual Meeting of the Association for Computational Linguistics: Long Papers, Vol.1. Association for Computational Linguistics, 2012. 873–882.

- [20] Pennington J, Socher R, Manning CD. Glove: Global vectors for word representation. In: Proc. of the Empirical Methods in Natural Language Processing (EMNLP 2014). 2014. 1532–1543.
- [21] Tillmann C, Ney H. Word reordering and a dynamic programming beam search algorithm for statistical machine translation. Computational Linguistics, 2003,29(1):97–133. [doi: 10.1162/089120103321337458]
- [22] Toutanova K, Klein D, Manning CD, Singer Y. Feature-Rich part-of-speech tagging with a cyclic dependency network. In: Proc. of the 2003 Conf. of the North American Chapter of the Association for Computational Linguistics on Human Language Technology, Vol.1. Association for Computational Linguistics, 2003. 173–180. [doi: 10.3115/1073445.1073478]
- [23] Zhou Q. Automatic translation from TCTbank to CCGbank: Ver 3.0. Technical Report, Beijing: Center for Speech and Language Technologies, Research Institute of Information Technology, Tsinghua University, 2011 (in Chinese).
- [24] Zhou Q. Annotation scheme for Chinese treebank. Journal of Chinese Information, 2004,18(4):1–8 (in Chinese with English abstract). [doi: 10.3969/j.issn.1003-0077.2004.04.001]
- [25] Bird S, Klein E, Loper E. Natural Language Processing with Python. O'Reilly Media, Inc., 2009.

附中文参考文献:

- [23] 周强.句法树库TCT到CCG bank的自动转换:设计规范 Ver 3.0.科技报告,北京:清华大学信息技术研究院语音和语言技术中心,2011.
- [24] 周强.汉语句法树库标注体系.中文信息学报,2004,18(4):1–8. [doi: 10.3969/j.issn.1003-0077.2004.04.001]



吴惠军(1987—),男,安徽阜阳人,硕士,主要研究领域为自然语言处理,机器学习.



宗成康(1963—),男,博士,研究员,博士生导师,CCF 杰出会员,主要研究领域为自然语言处理,机器翻译,情感分类.



张家俊(1983—),男,博士,副研究员,CCF 专业会员,主要研究领域为自然语言处理,机器翻译.