

# 基于数据选择和局部伪标注的跨领域语义依存分析研究

毛达展 喻快 邵艳秋\*

北京语言大学，信息科学学院，  
国家语言资源监测与研究平面媒体中心，  
北京市海淀区学院路 15 号，100083

maodazhan@foxmail.com yukuai\_get@163.com yqshao163@163.com

## 摘要

语义依存分析要走向实用，模型从单领域迁移到其他领域的领域适应能力至关重要。近年来，对抗学习针对领域适应这个任务取得了较好的效果，但对目标领域的无标注数据利用效率并不高。本文采用 Self-training 这种半监督学习方法，充分发挥无标注数据的潜能，弥补对抗学习方法的不足。但传统的 Self-training 效率和性能并不好，为此本文针对跨领域语义依存分析这个任务，尝试了强化学习数据选择器，提出了局部伪标注的标注策略，实验结果证明我们提出的模型优于基线模型。

**关键词：** 语义依存分析；领域适应；对抗学习；Self-training；局部伪标注

## Cross Domain Semantic Dependency Parsing with Data Selection and Pseudo Partial Annotation

Dazhan Mao Kuai Yu Yanqiu Shao\*

Information Science School, Beijing Language and Culture University,  
Language Resources Monitoring and Research Center,  
15 Xueyuan Road, HaiDian District, Beijing, 100083

maodazhan@foxmail.com yukuai\_get@163.com yqshao163@163.com

## Abstract

The ability to transfer from single domain to the other domain of model for cross domain semantic dependency parsing is variable, in order to make it practical. Recently, adversarial learning has made great performance in the task of domain adaptation. But, the utilization efficiency of unlabeled data still stays at a low level. From our view, self-training could cover this shortage and fully realize potential of these unlabeled data. Nevertheless, traditional self-training proved to be inefficient. Thus we tried apply multiple data selection strategies to cross domain semantic dependency parsing, and proposed pseudo partial annotation for self-training, which proved to be superior to baseline model.

**Keywords:** Semantic dependency parsing , Domain adaptation , Adversarial learning , Self-training , Pseudo partial annotation

\* 通讯作者 Corresponding Author

## 1 引言

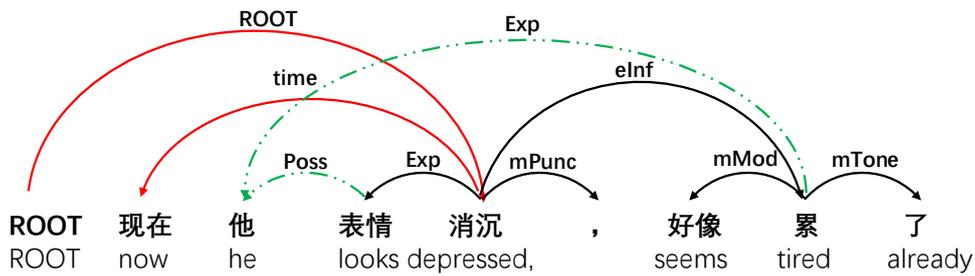


图 1. 语义依存分析示例。

语义依存分析 (邵艳秋 et al., 2016; Che et al., 2012) 不同于句法依存分析, 它描述的是深层次的语义解析, 语义依存图分析允许如多父节点、非投射等等更复杂的依存结构出现 (如图 1, 绿色虚线依存弧为多父节点现象, “他” 的父节点既有 “表情” 也有 “累”; 红色实线依存弧为非投射现象, 弧 “累” → “他” 和弧 “消沉” → “现在” 交叉。)。鉴于其能够直接表达深层的语义信息, 因此应用价值更大。目前已经有大量工作证明依存分析在信息抽取任务 (Gamallo and Garcia, 2012)、情感分析任务 (Poria et al., 2014; Caro and Grella, 2012) 和机器翻译任务 (Le et al., 2017; Chen et al., 2017; Wu et al., 2017), 等下游任务发挥较大的作用。

然而因为语义依存分析的数据集构建需要较多的语言学背景知识, 标注难度大, 试图通过标注目标领域的数据再直接训练一个依存分析器的做法是不现实的。因此研究语义依存分析的领域适应问题就显得非常有必要。本文的主要工作总结如下:

- 本文把强化学习**数据选择器**成功应用到了跨领域语义依存分析的目标领域数据扩充这个任务上, 它能够从伪标注数据中提取出高质量的目标领域数据, 从而提升了目标领域无标注数据的利用效率。
- 本文提出了**局部伪标注**的策略, 试图让数据选择器具备更强的数据选择能力, 从而提升伪标注数据的质量。该方法进一步提升了模型领域适应的能力。

## 2 相关工作

### 2.1 领域适应

BERT(Devlin et al., 2018)、XLNET(Yang et al., 2019)、RoBERTa(Liu et al., 2019) 等预训练模型用于下游任务的领域适应取得了较好的效果, 也包括语义依存分析 (毛达展 et al., 2020), 但在无标注数据上微调的训练代价较大。基于对抗学习的研究工作也层出不穷, 共享私有框架 (Share-Private) (Gui et al., 2017) 被用于词性标注的领域适应问题, (Chen and Cardie, 2018) 提出多项对抗网络 (Multinomial Adversarial Network, MAN) 来解决多领域文本分类问题。本文也将使用对抗学习作为我们模型的一部分。

### 2.2 自训练方法 Self-training

Self-training 作为一种半监督学习方法已经被广泛应用, 包括依存分析 (McClosky et al., 2008)、命名实体识别 (Liu et al., 2013) 等主流自然语言处理任务。但目前的大部分的 Self-

training 方法 (Ardehaly and Culotta, 2016; Zhou et al., 2012) 本质上都是基于置信度来选择伪标注数据。近年来关于使用强化学习来增强 Self-training (Mnih et al., 2015; Yang et al., 2018) 的工作不少, 试图解决置信度不可靠的问题。本文将使用 Self-training 用于解决目标领域数据的扩充, 从而达到领域适应的效果。

### 3 基线模型 WAdv-SelfTrain

我们首先提出一个解决跨领域语义依存分析的基线模型 **WAdv-SelfTrain**, 然后再进行改进研究。基线模型由三部分组成, 分别是 Biaffine 双仿网络、对抗模型和 Self-training。Biaffine 双仿网络用于解决语义依存分析本身, 对抗和 Self-training 都用于领域适应。

#### 3.1 Biaffine 双仿网络

我们使用 Biaffine 双仿网络 (Dozat and Manning, 2017) 分别来预测语义依存弧和语义标签, 就中文语义依存分析而言, 它是目前性能最好的依存分析器之一 (Shen et al., 2019)。

首先我们用词向量  $e_i^{(word)}$ , 词性向量  $e_i^{(pos)}$  和字符向量  $e_i^{(char)}$  得到词语的特征表示  $x_i$ ,

$$x_i = [e_i^{(word)}; e_i^{(pos)}; e_i^{(char)}] \quad (1)$$

然后用 Highway LSTM (Zilly et al., 2017) 编码  $x_i$ ,  $h_t^{lstm}$  表示 Highway LSTM 的输出,  $W_H$  和  $b_H$  是 Highway LSTM 的参数。

$$h_t^{lstm} = HighwayLSTM(x_i; W_H; b_H) \quad (2)$$

再使用 Biaffine 解码器计算弧的分数  $s_{i,j}^{edge}$ ,

$$s_{i,j}^{edge} = Biaffine^{edge}(h_i^{edge-dep}, h_j^{edge-head}) \quad (3)$$

$h_i^{edge-dep}$  和  $h_j^{edge-head}$  分别表示依存弧弧尾和依存弧弧头的向量表示。 $s_{i,j}^{label}$  的计算方式和  $s_{i,j}^{edge}$  类似。最后我们得到弧和标签的预测概率如下,

$$p_{i,j}^{edge} = sigmoid(s_{i,j}^{edge}) \quad (4)$$

$$p_{i,j}^{label} = softmax(s_{i,j}^{label}) \quad (5)$$

#### 3.2 对抗模型

在跨领域语义依存分析中, 对抗学习由两部分组成: 领域特征编码器和领域对抗判别器。领域特征编码器的优化目标是最大程度地混淆领域分类的正确性, 使领域特征更加“领域无关”; 领域对抗判别器的优化目标是最大程度地判别领域的类别, 减小对抗距离的损失。

本文具体参考 WGAN 的实现 (Arjovsky et al., 2017), 即采用 Wasserstein 距离的对抗判别器。Wasserstein 距离对抗损失  $L_{adv}^W$  表示如下,

$$L_{adv}^W(S^s, S^t) = f^W(S^s) - f^W(S^t) \quad (6)$$

其中  $f^W$  是一个 Lipschitz - 1 连续函数,  $S^s$  和  $S^t$  对应源领域和目标领域的特征表示。

基于 Wasserstein 距离的对抗学习是一个 minmax 训练过程, 即

$$\min_{\Theta^{dis}} \max_{\Theta^{share}} L_{adv}^W \quad (7)$$

其中  $\Theta^{dis}$  表示领域对抗判别器的参数,  $\Theta^{share}$  表示领域特征编码器的参数。

### 3.3 自训练方法 Ensemble style Self-training

在本文中 Self-training 的基本目标是挑选出合适的伪标注数据用于扩充依存分析器的目标领域训练集。我们参考集成式自训练方法 **Ensemble-style** Self-training 的做法 (Dong and Schafer, 2011; Yu et al., 2019), 用同样的训练集  $D_{train}$  不同的随机数种子分别训练 3 个依存分析器  $\{\Theta_1^{parser}, \Theta_2^{parser}, \Theta_3^{parser}\}$ 。弧和标签的预测概率将由 3 个依存分析器的结果取平均得出, 分别是  $p_{i,j}^{edge}$  和  $p_{i,j}^{label}$ 。

$$p_{i,j}^{edge} = \frac{\sum_{k=1}^3 p_{i,j,k}^{edge}}{3}, p_{i,j}^{label} = \frac{\sum_{k=1}^3 p_{i,j,k}^{label}}{3} \quad (8)$$

$$p_{i,j}^{label \cdot edge} = p_{i,j}^{edge} * I\{p_{i,j}^{label} > 0.5\} \quad (9)$$

$p_{i,j}^{label \cdot edge}$  表示弧和标签的“联合概率”。 $I\{p_{i,j}^{label} > 0.5\}$  表示若  $p_{i,j}^{label} > 0.5$  则  $I\{p_{i,j}^{label} > 0.5\}$  等于 1; 反之, 等于 0。

$$P = \frac{\sum_{i=1}^{|Word|} \sum_{j=1}^{|Word|+1} I\{p_{i,j}^{label \cdot edge} > \mu\}}{|Word|} \quad (10)$$

$|Word|$  表示依存句子分词后的词语数量,  $\mu$  表示  $p_{i,j}^{label \cdot edge}$  是该弧和标签被认为有效的阈值,  $P$  是置信度。

我们将目标领域无标注数据集  $D_{unlabeled}^{target}$  以置信度  $P > \alpha$  为过滤条件筛成子集  $\Omega$  ( $\alpha$  是伪标注句子被认为有效的阈值)。伪标注数据集  $\Omega$  又将以  $\phi\%$  的概率被随机采样成  $\Omega'$ , 最后  $\Omega'$  被扩充到  $D_{train}$  用于  $\{\Theta_1^{parser}, \Theta_2^{parser}, \Theta_3^{parser}\}$  的重新训练 (具体算法见图 2)。这里  $\Omega \rightarrow \Omega'$  不是按置信度  $P$  从高到低选取部分子集, 而是随机采样, 原因是考虑到置信度不是完全准确可靠的, (Chen and Zhang, 2018) 的案例研究中基于置信度的 Self-training 得出的置信度高的句子反而是错的。

---

**Algorithm** 跨领域语义依存分析  $\rightarrow$  集成式 Self-training

---

<p><b>Require:</b> <math>D_{train} = D_{train}^{source} \cup D_{train}^{target}</math>, <math>D_{dev} = D_{dev}^{source} \cup D_{dev}^{target}</math>, 目标领域无标注数据 <math>D_{unlabeled}^{target}</math></p> <p>1: 初始化伪标注数据集 <math>D_{pseudo}^{target} \leftarrow \emptyset</math></p> <p>2: <b>for</b> <math>i = 1</math> to <math>N_1</math> <b>do</b></p> <p>3: 用 <math>D_{train}</math> 和 <math>D_{pseudo}^{target}</math> 训练依存分析器 <math>\{\Theta_1^{parser}, \Theta_2^{parser}, \Theta_3^{parser}\}</math></p> <p>4: <math>Ensemble\{\Theta_1^{parser}, \Theta_2^{parser}, \Theta_3^{parser}\}</math> 在</p>	<p><math>D_{unlabeled}^{target}</math> 上做预测, 得到置信度 <math>P</math></p> <p>5: <math>D_{unlabeled}^{target}</math> 以置信度 <math>P &gt; \alpha</math> 为过滤条件筛成子集 <math>\Omega</math>, 随机采样 <math>\Omega</math> 得到 <math>\Omega'</math></p> <p>6: //扩充数据</p> <p>7: <math>D_{pseudo}^{target} \leftarrow D_{pseudo}^{target} \cup \Omega'</math></p> <p>8: <math>D_{unlabeled}^{target} \leftarrow D_{unlabeled}^{target} \setminus \Omega'</math></p> <p>9: <b>end for</b></p>
--	--

---

图 2. 自训练方法 Ensemble-style Self-training 算法流程。

### 3.4 联合训练

以上的模块损失整合起来, 总共是两个损失, 分别是对抗的损失  $L_{adv}^W$  和依存的损失  $L_{parser}$  (Self-training 部分没有损失)。因此本基线模型的损失  $L$  为:

$$L = L_{parser} + \gamma L_{adv}^W \quad (11)$$

注意，目标领域的无标注数据只影响  $L_{adv}^W$ ，用于领域适应，而  $L_{parser}$  只受源领域和目标领域的人工标注数据和伪标注数据影响。

## 4 模型 Our Model

基线模型只以置信度作为数据选择的依据，而选择的句子的语言特性却被忽略了 (Chen and Zhang, 2018)，而且置信度并不是完全可靠的 (Chen and Zhang, 2018)。我们分别从 Self-training 扩充数据的两个过程，数据选择和伪标注，分别来提高 Self-training 的性能。

- **数据选择**：数据选择可以被看成是一个“决策过程”，决定每一个被伪标注的句子是否被扩充进训练数据集。对于这个“决策过程”而言，输入是伪标注句子实例，输出是一个信号，表征拒绝还是接受这个伪标注实例。实际上，在强化学习 (Francois-Lavet et al., 2018) 中，这个“决策过程”可以被定义为一个策略网络，比如深度 Q-网络 (Mnih et al., 2015)，多层感知机 MLP (Yang et al., 2018; Ye et al., 2020) 等。深度 Q-网络比 MLP 网络复杂的多，且受限于网络的参数更新和反馈 Reward 的计算方式，数据选择的效率较差。相反，基于策略梯度算法 (Sutton et al., 2000) 来更新 MLP 网络，反馈 Reward 可以比较容易被批量计算，MLP 的参数也可以被批量更新，效率较高。因此本文将采用 MLP 网络作为 Self-training 数据选择的策略网络。
- **伪标注策略**：这里的标注策略指的是 Self-training 在伪标注无标注数据时，对句子结构的标注范围。目前监督学习多数的语料都是完整标注，然而当语料存在一定的标注难度时，局部标注 (Zhang et al., 2017; Guo et al., 2019) 是一个合理的选择。人工标注场景下选择局部标注主要出于数据量和标注一致性的考虑。当语料数据量较大的时候，标注能力有限，只挑有价值的部分标，从而在相同的标注能力下，标注更多的语料；标注者只要标注局部结构，可以增强标注者的注意力，使得标注者将注意力集中在重要的词语上，从而不同的标注者更容易达到一致的标注结果。受此启发，我们想到 Self-training 如果根据模型当前的能力，只标注句子最重要最有把握的部分，比起完整标注可以减少噪声。

### 4.1 强化学习数据选择器

如图 3，数据选择器通过动作 Action 和反馈 Reward 与依存分析器进行交互。数据选择器输入伪标注实例的状态表示 State，输出对应的 Action，决定是否接受这个伪实例；依存分析器利用数据选择器接受的伪实例进行训练，在验证集上的表现作为数据选择器本次决策的反馈 Reward，而 Reward 又将被用于下一次数据选择之前数据选择器的参数更新。数据选择器的优化目标是最大化 Reward，整个训练过程直到全部无标注数据  $D_{unlabeled}^{target}$  被扩充到训练集  $D_{train}^{source} \cup D_{train}^{target}$  或者模型的表现稳定结束（具体算法见图 4）。数据选择器的具体细节介绍如下。

- **State 状态表示**：本文用状态表示  $s_t$  表征一个伪实例作为数据选择器的输入。我们认为  $s_t$  包含两部分：(1) 当前伪实例输入依存分析器得到的 LSTM 隐藏层向量  $h_t$ ；(2) 依存分析器对当前伪实例的预测置信度  $p_t$ ，对应的网络参数为  $\{W_1, W_2, b_1\}$ 。因为  $s_t$  融合了  $h_t$  即句子的潜在特征表示，我们能够认为数据选择的决策过程考虑了句子的语言特性。

$$s_t = W_1 * h_t + W_2 * p_t + b_1 \quad (12)$$

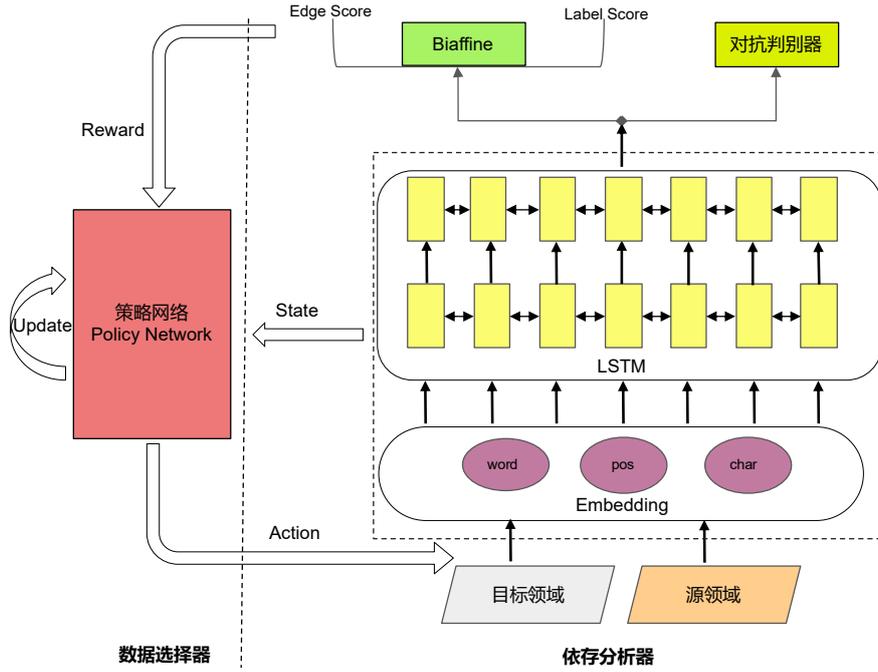


图 3. 应用强化学习数据选择器和对抗学习的跨领域语义依存分析器

- **MLP 策略网络**: 我们用  $A_{\Theta^{policy}}(a_t, s_t)$  表示 MLP 网络的预测概率。其中  $a_t$  决定当前  $s_t$  对应的伪实例是否能够被扩充进训练集。当  $a_t=1$  时，表示数据选择器接受当前伪实例并且扩充当前伪实例到训练集；当  $a_t=0$  时，表示数据选择器拒绝当前伪实例。而  $\Theta^{policy}$  则表示 MLP 策略网络，对应具体的网络参数是  $\{W_3, b_2\}$ 。ReLU 是激活函数 (Glorot et al., 2011)。

$$z_t = ReLU(s_t) \quad (13)$$

$$A_{\Theta^{policy}}(a_t, s_t) = softmax(W_3 * z_t + b_2) \quad (14)$$

- **Reward 反馈**: 如果数据选择器选择的伪实例导致依存分析器在验证集上的表现不好，那么 Reward 值是负的；相反，表现好，是正的。具体来说，Reward 值我们认为由两部分决定：(1) 源领域数据验证集  $D_{dev}^{source}$  上的表现；(2) 目标领域验证集  $D_{dev}^{target}$  上的表现。由于  $D_{dev}^{source}$  数据量大于  $D_{dev}^{target}$ ，如果不兼顾  $D_{dev}^{source}$  上的表现，容易过拟合。我们计算 Reward 值时，采用批量计算的方法，提高训练效率，指标是 LAS。假定目标领域无标注数据  $D_{unlabeled}^{target}$  有  $N_3$  批次  $\{B_1, \dots, B_k, \dots, B_{N_3}\}$ ，那么一轮数据选择下来得到的 LAS 序列分别是， $D_{dev}^{source} : \{LAS_1^{source}, \dots, LAS_k^{source}, \dots, LAS_{N_3}^{source}\}$ ， $D_{dev}^{target} : \{LAS_1^{target}, \dots, LAS_k^{target}, \dots, LAS_{N_3}^{target}\}$ 。

$$r_k = \frac{LAS_k^{source} - \mu^{source}}{\sigma^{source}} + \beta \frac{LAS_k^{target} - \mu^{target}}{\sigma^{target}} \quad (15)$$

其中  $r_k$  是  $B_k$  这个批次的 reward 值， $\mu^{source}$  和  $\mu^{target}$  分别是对应的 LAS 序列的样本均值， $\sigma^{source}$  和  $\sigma^{target}$  分别是对应的 LAS 序列的样本标准差， $\beta$  控制两者的权重。可以看出，表现最差的几个批次将得到负的 Reward 值，表现最好的几个批次将得到正的 Reward 值。

**Algorithm** 跨领域语义依存分析 → 强化学习增强的集成式 Self-training

<p><b>Require:</b> <math>D_{train} = D_{train}^{source} \cup D_{train}^{target}</math>, <math>D_{dev} = D_{dev}^{source} \cup D_{dev}^{target}</math>, 目标领域无标注数据 <math>D_{unlabeled}^{target}</math></p> <p>1: 初始化伪标注数据集 <math>D_{pseudo}^{target} \leftarrow \emptyset</math></p> <p>2: <b>for</b> <math>i = 1</math> to <math>N_1</math> <b>do</b></p> <p>3: 用 <math>D_{train}</math> 和 <math>D_{pseudo}^{target}</math> 训练依存分析器 <math>\{\Theta_1^{parser}, \Theta_2^{parser}, \Theta_3^{parser}\}</math></p> <p>4: 在 <math>D_{unlabeled}^{target}</math> 上做预测, 得到置信度 <math>P</math></p> <p>5: 按照置信度从高到低选取比例为 <math>\phi\%</math> 的 <math>D_{unlabeled}^{target}</math> 子集 <math>\Omega</math></p> <p>6: <b>for</b> <math>j = 1</math> to <math>N_2</math> <b>do</b></p> <p>7: 随机打乱 <math>\Omega</math>, 得到 <math>\{B_1, B_2, \dots, B_{N_3}\}</math></p> <p>8: <b>for</b> <math>k = 1</math> to <math>N_3</math> <b>do</b></p> <p>9: 对 <math>B_k</math> 应用强化学习数据选择器, 得到被接受的实例集合 <math>B_k^{accept}</math></p>	<p>10: 用 <math>B_k^{accept}</math> 训练依存分析器 <math>\{\Theta_1^{parser}, \Theta_2^{parser}, \Theta_3^{parser}\}</math></p> <p>11: 在 <math>D_{dev}^{source}</math> 和 <math>D_{dev}^{target}</math> 验证, 应用公式 (3) 得到 <math>r_k</math></p> <p>12: <b>end for</b></p> <p>13: // 更新策略网络</p> <p>14: <b>for</b> <math>k = 1</math> to <math>N_3</math> <b>do</b></p> <p>15: <math>\Theta^{policy} \leftarrow \Theta^{policy} + \lambda \frac{r_k}{ B_k } \sum_{t=1}^{ B_k } A_{\Theta^{policy}}(a_t, s_t)</math></p> <p>16: <b>end for</b></p> <p>17: <b>end for</b></p> <p>18: // 扩充数据</p> <p>19: <math>D_{pseudo_i}^{target} \leftarrow D_{pseudo}^{target} \cup_{k=1}^{N_3} B_k^{accept}</math></p> <p>20: <math>D_{pseudo}^{target} \leftarrow D_{pseudo}^{target} \cup D_{pseudo_i}^{target}</math></p> <p>21: <math>D_{unlabeled}^{target} \leftarrow D_{unlabeled}^{target} \setminus D_{pseudo_i}^{target}</math></p> <p>22: <b>end for</b></p>
--	--

**图 4.** 强化学习增强的自训练方法 Ensemble-style Self-training 算法流程。

- **训练:** 基于最大化 Reward 值的训练目标, 我们用策略梯度算法 (Sutton et al., 2000) 来更新 MLP 策略网络的参数。

$$\Theta^{policy} = \Theta^{policy} + \lambda \frac{r_k}{|B_k|} \sum_{t=1}^{|B_k|} A_{\Theta^{policy}}(a_t, s_t) \quad (16)$$

其中  $|B_k|$  表示  $B_k$  这个批次无标注数据的数量。

#### 4.2 局部标注



**图 5.** 局部标注句子示例。只保留了“消沉” → “表情”和“累” → “好像”两条弧。

如图 5, 我们在 Self-training 伪标注句子时, 只选择一部分结构去标注。至于具体选择哪些部分结构去标注, 我们借鉴了 (Zhang et al., 2017) 人工标注的做法, 尝试如下两种策略对 Self-training 局部伪标注进行研究。

- **Certainty 确定性策略:** 基线模型中 Self-training 的一条伪标注句子被接受的条件要看整条句子满足  $p_{i,j}^{label-edge} > \mu$  的比例, 即置信度  $P$ 。而一旦满足  $P > \alpha$ , 剩下的  $1 - P$  的弧和标签也将被一起作为句子的一部分用于训练依存分析器, 这部分从置信度的角度来说就是误差。因此, 确定性策略就是对满足  $P > \alpha$  条件的伪标注句子仅仅保留弧和标签满足  $c_{i,j} = p_{i,j}^{label-edge} > \mu$  条件的部分, 即保留比例为  $100 * P\%$  的部分。确定性策略对应统计学“样本均值”的概念, 目标是让“样本均值”尽可能大。
- **Divergence 分歧策略:** 确定性策略中依赖的  $p_{i,j}^{label-edge}$  是“平均意义”的预测概率, 平均值在极端情况下并不准确。为此我们仍然使用公式 (10) 计算得到的置信度  $P$  作为筛选句

子的条件，但是保留弧和标签的条件不再使用  $c_{i,j} = p_{i,j}^{\overline{\text{label-edge}}} > \mu$ ，而是使用条件  $d_{i,j} < \delta$ 。 $d_{i,j}$  的定义如下：

$$p_{i,j,k}^{\text{label-edge}} = p_{i,j,k}^{\text{label}} * I\{p_{i,j,k}^{\text{edge}} > 0.5\}, k = 1, 2, 3$$

$$d_{i,j} = |\max(p_{i,j,k}^{\text{label-edge}})_{k=1,2,3} - \min(p_{i,j,k}^{\text{label-edge}})_{k=1,2,3}|$$
(17)

$d_{i,j}$  的值越小，说明 3 个依存分析器的预测结果分歧越小。分歧性策略对应统计学“样本方差”的概念，目标是让“样本方差”尽可能小。

- **Mixed 混合策略**：混合策略就是结合确定性策略和分歧策略，被筛出来的伪标注句子保留弧时不仅要满足  $c_{i,j} > \mu$  也要满足  $d_{i,j} < \delta$ 。为此定义  $m_{i,j}^{\text{label-edge}} > \nu$  作为混合策略保留弧的条件。

$$m_{i,j} = c_{i,j} - d_{i,j}$$
(18)

## 5 实验部分

### 5.1 数据集介绍

本实验的数据集包括源领域数据集和目标领域数据集，源领域来自博雅汉语和 the SemEval-2016 task9(Che et al., 2012) 的平衡语料，目标领域是 4 个子领域分别是散文、小说、医疗和司法。其中目标领域包括有标注数据和无标注数据，无标注数据将用于帮助对抗训练以及 Self-training。对源领域数据集和目标领域数据集我们均进行了数据集划分，如下表 1。

表 1. 数据集划分

领域说明		人工标注数据集			无标注数据	
		训练集	验证集	测试集		
源领域	平衡语料	38000	2000	2000	0	
目标领域	文学	散文	3000	1000	1000	60000
		小说	3000	1000	1000	60000
	应用	医疗	2000	500	500	60000
		司法	2000	500	500	60000

### 5.2 实验设置

我们使用带标记依存正确率(LAS)作为验证集和测试集的评价指标。依存分析器中的 LSTM 维度设为 400, Embedding 层和 LSTM 层的 dropout(Hinton et al., 2012) 比例分别为 0.2 和 0.3, 对抗损失的权重  $\gamma$  设置为 0.1。伪标注数据的随机采样概率  $\phi\%$  为 25%，标签和弧的阈值  $\mu$  为 0.75, 句子阈值  $\alpha$  为 0.5。数据选择器的 Reward 的  $Dev_{dev}^{\text{target}}$  权重  $\beta$  为 0.75。对抗学习的学习率为 0.0001, 数据选择器的学习率为 0.0005。对抗学习的 min 训练和 max 训练的交替比例为 4:1。局部标注策略的分歧阈值  $\delta$  设置为 0.15, 混合阈值  $\nu$  为 0.6。本文使用单卡完成训练，单卡的批量大小设置为 32。

### 5.3 实验结果

表 2 展示了我们的模型和基线模型在目标领域测试集上的实验结果，所有实验结果均多次运行取平均。基线模型有 3 个，分别是 **Transfer**、**WAdv** 和 **WAdv-SelfTrain**。**Transfer**

指的是训练时在源领域数据上预训练，然后再在对应的目标领域上进一步训练。数据选择器中 **Ensemble-style** 就是之前提到的集成式 Self-training 数据选择方法，**RL** 则是强化学习数据选择器。值得说明的是这里 **WAdv** 目标领域无标注数据也全部用到了，用于领域判别器的训练。

在小说领域，最优结果是 **RL+ 混合策略**，相比三个基线模型分别提高 5.6%、2.97% 和 1.9%；在散文领域，最优结果是 **RL+ 确定性策略**，相比三个基线模型分别提高 8.5%、2.88% 和 1.73%；在医疗领域，最优结果是 **RL+ 混合策略**，相比三个基线模型分别提高 6.53%、3.54% 和 2.49%；在司法领域，最优结果是 **RL+ 混合策略**，相比三个基线模型分别提高 5.38%、4.25% 和 1.74%。

实验结果显著地证明了，强化学习选择器和局部标注策略领域适应的效果。但因为不同目标领域的的数据特性和语言特性不一致，因此最优方法并不一样。但大部分情况下，**RL+ 混合策略** 都取得了最好的结果。

表 2. 本工作的模型和基线模型在 4 个目标领域上的 LAS 指标

模型	数据选择器	局部标注	结果 (LAS (%))				
			小说	散文	医疗	司法	Average
Transfer	—	—	73.39	70.25	68.22	68.12	69.99
WAdv	—	—	75.33	74.09	70.19	69.89	72.38
WAdv-SelfTrain	Ensemble-style	—	76.12	74.43	70.91	70.56	73.01
Our Model	Ensemble-style	确定性	76.45	74.64	70.86	70.78	73.18
	Ensemble-style	分歧	76.14	74.36	70.74	70.51	72.94
	Ensemble-style	混合	76.67	74.79	70.98	70.65	73.27
	RL	确定性	77.37	<b>76.23</b>	72.24	71.43	74.32
	RL	分歧	77.32	76.01	72.32	71.64	74.32
	RL	混合	<b>77.57</b>	75.89	<b>72.68</b>	<b>71.79</b>	74.48
	RL	—	77.01	75.74	71.74	71.15	73.91
	Ensemble-style	Average	76.42	74.60	70.86	70.65	—
	RL	Average	77.42	76.04	72.41	71.62	—

#### 5.4 数据选择器和局部标注策略的分析

- **数据选择器的分析**：表 2 的实验结果包含了消融实验，可以看出 **RL** 对领域适应的性能提升比较明显。有局部标注策略的时候，通过 3 种策略的结果取平均，我们计算出在 4 个领域的综合表现 **RL** 相对 **Ensemble-style** 分别提升了 1.31%、1.94%、2.19% 和 1.38%；无局部标注策略的时候，分别提升 1.16%、1.76%、1.17% 和 0.83%。有无局部标注策略的差别，也从侧面验证了局部标注策略的作用。
- **局部标注策略的分析**：从前面的分析可以看出，实验结果的大部分情况下混合策略占优势，这也符合常理，因为混合性策略两个方面都考虑到了。当使用 **RL** 数据选择器时，平均 4 个领域的结果，3 种局部伪标注策略分别相对完整伪标注提升 0.54%、0.55% 和 0.91%。使用 **Ensemble style** 数据选择器，平均 4 个领域的结果，分别提升 0.24%、0.28% 和 0.78%。我们发现使用 **RL** 后，局部伪标注策略的表现更好了，可能是因为 **RL** 的策略网络把句子的向量表示作为输入，对句子信息的抽取能力比起置信度阈值这种手段更强，由此也就更有把握句子结构中正确概率最高的部分。

#### 5.5 对无标注数据利用率的分析

本文用 Self-training 方法做领域适应的初衷就是提高无标注数据的利用效率，尽管对抗学习也能利用无标注数据进行领域判别器的训练，但利用效率是较低的。为此，我们把 6w 条无

标注数据划分为 10 等份，探究四个领域的最优方法和对抗学习 **WAdv** 无标注数据量从 0% 到 100% 的表现。如图 6, **WAdv** 对应的表现大概在 60%-70% 就稳定下来了，后面注入更多的数据甚至有性能下降的情况，可能噪声变强了，而模型的拟合能力又到顶了。而相同的数据量的情况下，强化学习选择器和局部标注策略对应的最优方法几乎总是表现优于 **WAdv**，并且在数据量到达 100% 的时候，仍保持上升的趋势，这其实也说明 6w 条无标注数据还没充分挖掘模型的性能，我们的方法对无标注数据的领域信息提取能力、数据利用效率都优于 **WAdv**。

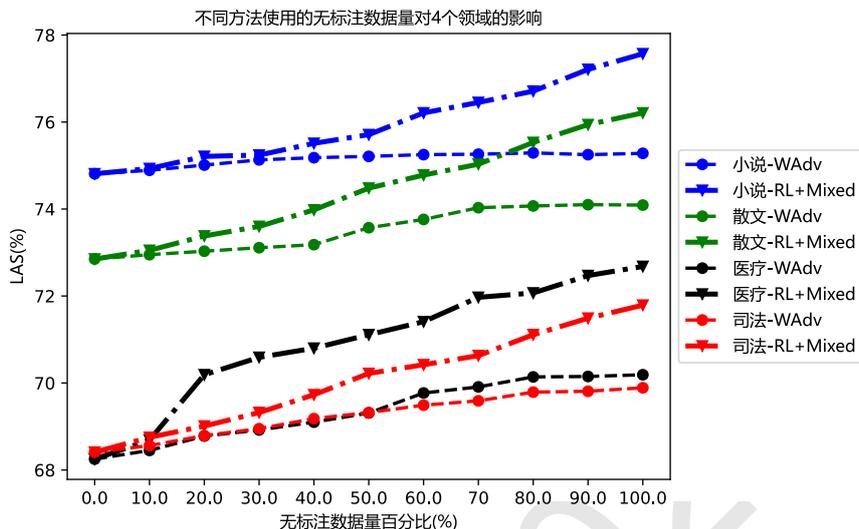


图 6. 最优模型与对抗模型对无标注数据利用效率的对比

## 6 结论

本文基于 Self-training 对语义依存分析的领域适应进行研究。本文的主要贡献有：从数据选择器和伪标注策略两个角度对 Self-training 的基线模型进行了改进，利用强化学习数据选择器从 6w 规模的目标领域无标注数据中提取了更高质量的伪标注数据，并提出 3 种相互联系的局部伪标注策略用于提取伪标注数据的最有价值的句子结构信息用于数据选择，进而扩充进训练数据集，提升了模型领域适应的能力；对比了我们的方法和我们的方法对无标注数据的利用效率，证明了我们的方法不仅对无标注数据的利用规模大于对抗模型，相同数据规模下也具备更强的领域信息提取能力，得出结论：目标领域无标注数据具备丰富的领域信息，通过设计更好的 Self-training 方法就能够提取出高质量的领域信息用于提升模型整体的领域适应性能，并且它并不受限于具体的模型架构，可以很好地和对抗模型进行融合，弥补对抗学习对无标注数据利用效率不高的不足。

## 致谢

本成果受国家自然科学基金项目 (61872402)，教育部人文社科规划基金项目 (17YJAZH068)，北京语言大学校级项目 (中央高校基本科研业务费专项资金) (18ZDJ03)，模式识别国家重点实验室开放课题基金资助。

## 参考文献

- Ehsan Mohammady Ardehaly and Aron Culotta. 2016. Domain adaptation for learning from label proportions using self-training.
- Martin Arjovsky, Soumith Chintala, and Leon Bottou. 2017. Wasserstein gan.
- L Di Caro and M Grella. 2012. Sentiment analysis via dependency parsing.
- Wanxiang Che, Meishan Zhang, Yanqiu Shao, and Ting Liu. 2012. Chinese semantic dependency parsing.
- Xilun Chen and Claire Cardie. 2018. Multinomial adversarial networks for multi-domain text classification.
- Chenhua Chen and Yue Zhang. 2018. Learning how to self-learn: Enhancing self-training using neural reinforcement learning.
- Kehai Chen, Rui Wang, Masao Utiyama, Lema Liu, Akihiro Tamura, Eiichiro Sumita, and Tiejun Zhao. 2017. Neural machine translation with source dependency representation.
- Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. 2018. Bert: Pre-training of deep bidirectional transformers for language understanding.
- Cailing Dong and Ulrich Schafer. 2011. Ensemble-style self-training on citation classification.
- Timothy Dozat and Christopher D. Manning. 2017. Deep biaffine attention for neural dependency parsing.
- Vincent Francois-Lavet, Peter Henderson, Riashat Islam, MarcG Bellemare, and Joelle Pineau. 2018. *An Introduction to Deep Reinforcement Learning*.
- Pablo Gamallo and Marcos Garcia. 2012. Dependency-based open information extraction.
- Xavier Glorot, Antoine Bordes, and Yoshua Bengio. 2011. Deep sparse rectifier neural networks.
- Tao Gui, Qi Zhang, Haoran Huang, Minlong Peng, and Xuanjing Huang. 2017. Part-of-speech tagging for twitter with adversarial neural networks.
- Lijuan Guo, Xue Peng, Zhenghua Li, and Zhang Min. 2019. Construction of chinese dependency syntax treebanks for multi-domain and multi-source texts.
- Geoffrey E. Hinton, Nitish Srivastava, Alex Krizhevsky, Ilya Sutskever, and Ruslan R. Salakhutdinov. 2012. Improving neural networks by preventing co-adaptation of feature detectors.
- An Nguyen Le, Ander Martinez, Akifumi Yoshimoto, and Yuji Matsumoto. 2017. Improving sequence to sequence neural machine translation by utilizing syntactic dependency information.
- Qian Liu, Bingyang Liu, Dayong Wu, Yue Liu, and Xueqi Cheng. 2013. A self-learning template approach for recognizing named entities from web text.
- Yinhan Liu, Myle Ott, Naman Goyal, Jingfei Du, Mandar Joshi, Danqi Chen, Omer Levy, Mike Lewis, Luke Zettlemoyer, and Veselin Stoyanov. 2019. Roberta: A robustly optimized bert pretraining approach.
- David McClosky, Eugene Charniak, and Mark Johnson. 2008. When is self-training effective for parsing.
- Volodymyr Mnih, Koray Kavukcuoglu, David Silver, Andrei A Rusu, Joel Veness, Marc G Bellemare, Alex Graves, Martin Riedmiller, Andreas K Fidjeland, and Georg Ostrovski. 2015. Human-level control through deep reinforcement learning.
- Soujanya Poria, Nir Ofek, Alexander Gelbukh, and L. Rokach A. Hussain. 2014. Dependency tree-based rules for concept-level aspect-based sentiment analysis.
- Zizhuo Shen, Huayong Li, Dianqing Liu, and Yanqiu Shao. 2019. Dependency-gated cascade biaffine network for chinese semantic dependency graph parsing.
- Richard S Sutton, David A McAllester, Satinder P Singh, and Yishay Mansour. 2000. Policy gradient methods for reinforcement learning with function approximation.

- Shuangzhi Wu, Dongdong Zhang, Nan Yang, Mu Li, and Ming Zhou. 2017. Dependency-to-dependency neural machine translation.
- Yaosheng Yang, Wenliang Chen, Zhenghua Li, Zhengqiu He, and Min Zhang. 2018. Distantly supervised ner with partial annotation learning and reinforcement learning.
- Zhilin Yang, Zihang Dai, Yiming Yang, Jaime Carbonell, Ruslan Salakhutdinov, and Quoc V Le. 2019. Xlnet: Generalized autoregressive pretraining for language understanding.
- Zhiqian Ye, Yuxia Geng, Jiaoyan Chen, Xiaoxiao Xu, Suhang Zheng, Feng Wang, Jingmin Chen, Jun Zhang, and HuaJun Chen. 2020. Zero-shot text classification via reinforced self-training.
- Nan Yu, Zonglin Liu, Ranran Zhen, Tao Liu, Meishan Zhang, and Guohong Fu. 2019. Domain information enhanced dependency parser.
- Yue Zhang, Zhenghua Li, Jun Lang, Qingrong Xia, and Min Zhang. 2017. Dependency parsing with partial annotations: An empirical comparison.
- Yan Zhou, Murat Kantarcioglu, and Bhavani Thuraisingham. 2012. Self-training with selection-by rejection.
- Julian Georg Zilly, Rupesh Kumar Srivastava, Jan Koutnik, and Jurgen Schmidhuber. 2017. Recurrent highway networks.
- 毛达展, 李华勇, and 邵艳秋. 2020. 半监督跨领域语义依存分析技术研究. In *Proceedings of the 19th Chinese National Conference on Computational Linguistics*, pages 783–794, Haikou, China, October. Chinese Information Processing Society of China.
- 邵艳秋, 宋勇康, 李华勇, 王颖哲, 张文敏, and 赵玉杭. 2016. 中文语义依存图标注规范. Website. [https://csdp-doc.readthedocs.io/zh\\_CN/latest/](https://csdp-doc.readthedocs.io/zh_CN/latest/).