



基于自适应损失函数的句子级远程监督关系抽取

胡峰, 杨新瑞, 汤成富, 邓维斌, 刘群

引用本文:

胡峰, 杨新瑞, 汤成富, 邓维斌, 刘群. 基于自适应损失函数的句子级远程监督关系抽取[J]. 智能系统学报, 2024, 19(3): 697-706.

HU Feng, YANG Xinrui, TANG Chengfu, et al. Sentence-level distant supervision relation extraction based on self-adaptive loss function[J]. *CAAI Transactions on Intelligent Systems*, 2024, 19(3): 697-706.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202205034>

您可能感兴趣的其他文章

用于关系抽取的注意力图长短时记忆神经网络

Attention graph long short-term memory neural network for relation extraction

智能系统学报. 2021, 16(3): 518-527 <https://dx.doi.org/10.11992/tis.202008036>

基于分类差异与信息熵对抗的无监督域适应算法

Unsupervised domain adaptation algorithm based on classification discrepancy and information entropy

智能系统学报. 2021, 16(6): 999-1006 <https://dx.doi.org/10.11992/tis.202010020>

鲁棒的半监督多标签特征选择方法

A robust, semi-supervised, and multi-label feature selection method

智能系统学报. 2019, 14(4): 812-819 <https://dx.doi.org/10.11992/tis.201809017>

面向中文开放领域的多元实体关系抽取研究

Chinese open domain oriented n-ary entity relation extraction

智能系统学报. 2019, 14(3): 597-604 <https://dx.doi.org/10.11992/tis.201805006>

应用于不平衡多分类问题的损失平衡函数

Application of the loss balance function to the imbalanced multi-classification problems

智能系统学报. 2019, 14(5): 953-958 <https://dx.doi.org/10.11992/tis.201808004>

基于低秩分解的鲁棒典型相关分析

Robust canonical correlation analysis based on low rank decomposition

智能系统学报. 2017, 12(4): 491-497 <https://dx.doi.org/10.11992/tis.201607024>

DOI: 10.11992/tis.202205034

网络出版地址: <https://link.cnki.net/urlid/23.1538.tp.20231008.0859.002>

基于自适应损失函数的句子级远程监督关系抽取

胡峰, 杨新瑞, 汤成富, 邓维斌, 刘群

(重庆邮电大学 计算智能重庆市重点实验室, 重庆 400065)

摘要: 远程监督关系抽取是一种关系抽取方法, 现有方法主要采用多实例学习, 在具有相同实体对的样例包上进行关系抽取。但是, 包级方法只能缓解却并不能完全解决错误标签问题。基于此, 文中首先分析了干净数据和噪声数据的分布, 提出了一种新的自适应损失函数; 在此基础上, 提出了一种基于自适应损失函数的句子级远程监督关系抽取方法。在公开数据集 NYT-10 以及基于 TACRED 的合成数据集上的实验结果表明: 文中提出的方法优于对比文献中的方法, 能够更有效地区分错误标签噪声样例和干净样例, 提高了句子级远程监督关系抽取的准确率。

关键词: 自然语言处理; 信息抽取; 关系抽取; 远程监督; 噪声分离; 噪声标注; 负训练; 自适应损失函数

中图分类号: TP391 **文献标志码:** A **文章编号:** 1673-4785(2024)03-0697-10

中文引用格式: 胡峰, 杨新瑞, 汤成富, 等. 基于自适应损失函数的句子级远程监督关系抽取 [J]. 智能系统学报, 2024, 19(3): 697-706.

英文引用格式: HU Feng, YANG Xinrui, TANG Chengfu, et al. Sentence-level distant supervision relation extraction based on self-adaptive loss function[J]. CAAI transactions on intelligent systems, 2024, 19(3): 697-706.

Sentence-level distant supervision relation extraction based on self-adaptive loss function

HU Feng, YANG Xinrui, TANG Chengfu, DENG Weibin, LIU Qun

(Chongqing Key Laboratory of Computational Intelligence, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: Distant supervision relation extraction is a kind of relation extraction method. The existing methods, which mainly employ multi-instance learning and relation extraction, are conducted in the sample bag that contains the same entity pair. However, the bag-level method can only alleviate but cannot completely solve the problem of wrong labeling. Therefore, herein, the distribution of clean data and noise data is analyzed, proposing a new self-adaptive loss function. On this basis, a method for sentence-level distant supervision relation extraction based on self-adaptive loss function is given. The experimental results obtained on the public dataset NYT-10 and the TACRED-based synthetic dataset show that the proposed method is better than that given in the compared studies. It can distinguish the wrongly labeled noise samples from the clean samples more effectively, improving the accuracy of sentence-level distant supervision relation extraction.

Keywords: natural language processing; information extraction; relation extraction; distant supervision; noise separation; noise label; negative training; self-adaptive loss function

关系抽取 (relation extraction, RE) 是信息抽取的主要子任务之一, 旨在从一段文本中抽取两个实体名词之间存在的关系信息, 将半结构化、非结构化文本数据转化为结构化的实体关系三元组以用于各种下游任务中, 如知识图谱的构建与补齐、问答系统、机器翻译等^[1]。为解决人工标注

大规模数据集成本过高的问题, Mintz 等^[2]提出了远程监督关系抽取 (distance relation extraction) 的方法。为缓解远程监督带来的错误标签噪声问题, Riedel 等^[3]提出多实例学习方法 (multi-instance learning, MIL) 进行包级别的关系抽取。但采用包级关系抽取会导致无法明确与包中每个句子映射的句子级标签, 限制了在一些需要句子级关系的下游任务中的应用^[4-5]。之后的几项研究^[6-7]也验证了包级关系抽取在句子级评估上的性能不足。因此, 仍然需要研究有效的句子级降噪方法

收稿日期: 2022-05-23. 网络出版日期: 2023-10-09.

基金项目: 国家重点研发计划项目 (2018YFC0832102); 重庆市教委重点合作项目 (HZ2021008); 重庆市自然科学基金项目 (cstc2021jcyj-msxmX0849).

通信作者: 胡峰. E-mail: hufeng@cqupt.edu.cn.

来解决远程监督数据集中的错误标签噪声问题。2021 年, Ma 等^[8]提出了一种句子级的远程监督关系抽取框架——SENT, 采用负训练^[8-9] (negative training, NT) 方式有效降低了模型对噪声数据的过度拟合, 且在一定程度上分离了噪声数据和干净数据。但 SENT 方法降噪性能的收敛速度较慢, 需要经过多轮模型迭代训练才能达到一个较好的降噪效果; 此外, SENT 方法对噪声与干净数据的分离距离仍然不足, 降噪阈值邻域区间仍存在大量干净数据和噪声数据混杂在一起, 导致降噪性能不稳定。如果能加大噪声数据和干净数据的分离距, 将噪声数据和干净数据分别集中在低置信度区间和高置信度区间, 减少中部区间的样本数量, 则可降低阈值参数设置的敏感度, 提升模型降噪性能的稳定性和收敛速度。本文根据噪声数据和干净数据的分布规律, 提出了一种新的自适应加权损失函数 ANTLoss(self-adaptive negative training loss), 该损失函数可以减小噪声数据和干净数据的学习权重, 进而抑制模型对噪声数据和简单干净数据的拟合, 使其将更多的注意力集中在中部区间混杂难分的数据上, 将噪声数据与干净数据更大程度的分离开来。在此基础上, 本文提出了一种基于自适应损失函数的句子级远程监督关系抽取算法。实验结果表明, 本文方法性能优于文献中的方法, 在降噪与分类性能方面都有所提升。本文的主要工作贡献如下:

1) 在 SENT 框架的基础上对负训练损失函数进行改进, 提出了一种新的可以根据训练样本概率分布变化进行动态调整的自适应加权损失函数。该方法与模型无关, 可应用于其他存在错误标签噪声的任务中。

2) 提出了一种基于自适应损失函数的句子级远程监督关系抽取算法。

1 相关工作

Mintz 等^[2]在 2009 年提出了远程监督关系抽取方法, 用于解决人工标注大规模数据集成本过高的问题。该方法基于已有的关系知识库, 将知识库中的实体对与大规模未标注的语料库进行自动对齐, 生成有标注的训练数据集。其基于这样一种假设: 对于知识库中已存在的一个实体对 (e_1, e_2) 具有关系 r , 则外部语料中任何提及实体对 (e_1, e_2) 的句子都具有关系 r 。但是, 该方法仅关注文本和知识库中是否有相同的实体对, 忽视了实体对在不同上下文语境下可能会有不同的关系表现, 不可避免地带来了错误标签噪声问题。为缓解该问题, Riedel 等^[3]将假设松弛到“关系至少出现一次”的程度, 进而提出了多实例学习方法^[10-11], 用包级关系抽取来缓解噪声问题。包级关系抽取

将具有相同实体对的样例打包为一个句子包, 每个句子包具有一个包级标签, 模型训练和测试都在包级别上进行。基于多实例学习的降噪研究主要分为两种: 1) 软降噪方法, 通过注意力机制为包内、包间句子分配不同权重以降低噪声句子的影响力^[12-14]或为样本打上软标签^[15]; 2) 硬降噪方法, 使用强化学习或对抗生成网络直接从包中去除噪声句子^[7,16]。

Shang 等^[17]认为之前大多数降噪方法所忽略的噪声样例并非无用的数据, 而是缺乏正确的关系标签。如果能为噪声样例打上正确的关系标签, 则既能减少噪声句子的负面影响, 又能增加有用训练数据的数量。基于此, 文献^[17]提出了一种基于深度聚类网络的降噪模型, 可用于噪声数据的重新标注。该方法是一个包级降噪方法, 虽然能在一定程度上缓解噪声问题, 但仍无法明确与包中每个句子映射的句子级标签。如图 1 所示, 对于包级样例, 我们无法确定其包级标签是属于“Place_of_birth”还是“Employee_of”, 也无法明确与每一句话对应的句子级标签; 此外, 对于“Obama was back to the United States”这句话, 其实际对应的真实关系是“Lived_in”, 但该关系并不存在于包级标签的关系集合中。因此, 此后的一些工作开始进行句子级的降噪研究。Jia 等^[6]提出了一种基于注意力正则的句子级降噪框架。Ma 等^[8]提出了一种基于负训练的句子级降噪框架来对噪声数据进行分离并重新标注, 达到了目前句子级降噪的最好效果。

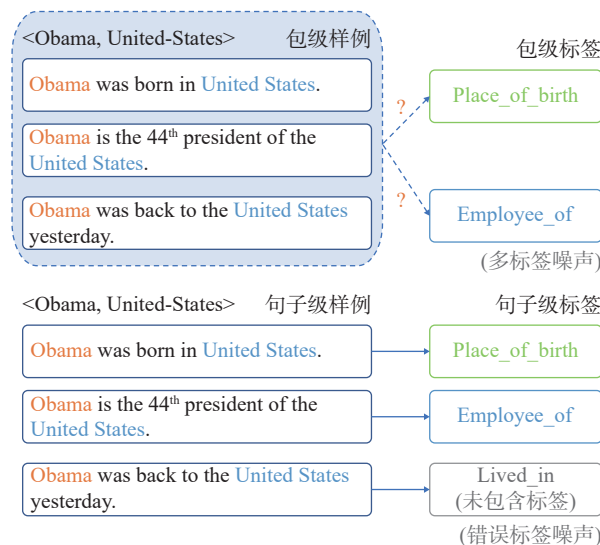


图 1 包级标签与句子级标签对比

Fig. 1 Comparison of bag-level label and sentence-level label

在远程监督中, 也可通过使用动态损失函数来进行降噪。Lin 等^[18]于 2017 年提出 Focal Loss, Tan 等^[19]在其基础上提出了基于动态 Focal Loss

的文档级关系抽取模型。彭正阳等^[20]提出了一种基于动态损失函数的包级远程监督关系抽取模型, 但该方法存在训练初期不稳定的问题。

2 句子级远程监督关系抽取

在本任务中, 将句子级输入样例表示为 $S^* = \{(s_1, y_1^*), (s_2, y_2^*), \dots, (s_N, y_N^*)\}$, 每个句子 s_i 包含一个实

体对 (e_1, e_2) 和与之对应的标签 $y_i^* \in \mathbf{R} = \{1, 2, \dots, C\}$, C 是关系类别个数。由于 y^* 是来自于远程监督数据集中的包级标签, 很显然是带有噪声的, S^* 是一个带有噪声的数据集。我们将没有噪声的真实数据集表示为 $S = \{(s_1, y_1), (s_2, y_2), \dots, (s_N, y_N)\}$ 。

本文的研究工作在 SENT 框架的基础上展开。句子级关系抽取降噪框架如图 2 所示。

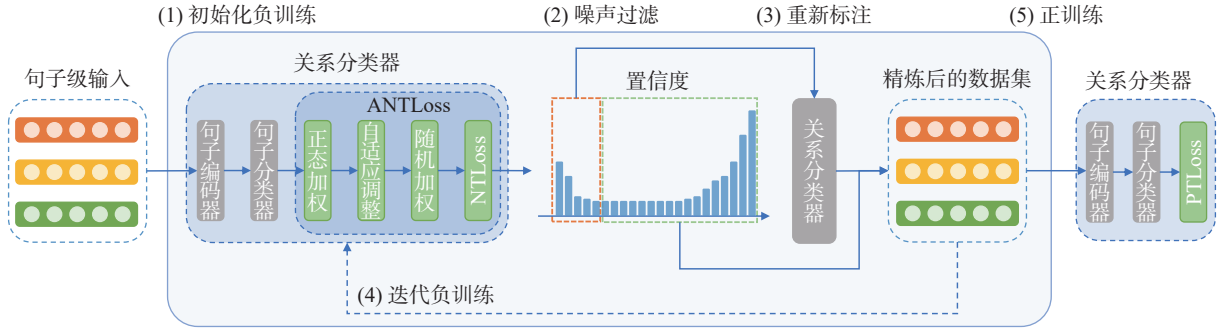


图 2 句子级关系抽取降噪框架

Fig. 2 Sentence-level relation extraction denoise framework

为实现句子级的远程监督关系抽取, 需要经过如下步骤:

1) 在数据集 S^* 上进行负训练 (negative training, NT), 得到一个关系分类器;

2) 执行噪声过滤过程, 从数据集 S^* 中划分出噪声数据集 $S_n^* = \{(s_i, y_i^*) | y_i^* \neq y_i\}$;

3) 执行重新标注过程, 对 S_n^* 进行重新标注得到 $S_{n, \text{relabelled}}^* = \{(s_i, y_i^*) | (s_i, y_i^*) \in S_n^*\}$, 以及精炼后的数据集 $S_{\text{refined}}^* = (S^* \setminus S_n^*) \cup S_{n, \text{relabelled}}^*$;

4) 使用精炼后的 S_{refined}^* 迭代执行负训练、噪声过滤、重新标注过程, 直到精炼后的数据集 S_{refined}^* 接近于真实数据集 S ;

5) 在精炼后的数据集 S_{refined}^* 上执行正训练 (positive training, PT), 得到最终的关系分类器。

本文工作主要在于负训练中所使用的 ANTLoss 函数, 该损失函数包含 3 个关键环节: 正态加权、权重自适应调整和随机加权。

2.1 加权损失函数

传统的分类模型训练通常采用正训练, 即“输入的句子属于这个标签”。对于输入句子 s 有标签 $y^* \in \mathbf{R} = \{1, 2, \dots, C\}$, 其中, C 维 one-hot 向量表示为 $\mathbf{y} \in \{0, 1\}^C$ 。 $\mathbf{p} = f(s)$ 表示将句子 s 输入关系分类器 $f(\cdot)$ 所得到的概率向量。以交叉熵损失函数为例, 正训练损失函数 PTLoss 定义为

$$L_{\text{PT}}(f, y^*) = - \sum_{j=1}^C y_j \log(p_j) \quad (1)$$

式中: p_j 表示第 j 类的概率, 随着损失的减小, $p_j \rightarrow 1$ 。

与正训练思路相反, 在负训练中模型要预测“输入句子不属于这个标签的互补标签”。对于带有标签 $y^* \in \mathbf{R}$ 的句子 s , 我们在 y^* 之外的标签集合中随机采样以构造其互补标签 $\bar{y}^* \in \mathbf{R} \setminus \{y^*\}$ 。同样以交叉熵损失函数为例, 负训练损失函数 NTLoss 定义为

$$L_{\text{NT}}(f, y^*) = - \sum_{j=1}^C \bar{y}_j \log(1 - p_j) \quad (2)$$

式 (2) 旨在降低模型对互补标签的预测概率, 随着损失的减小, $p_j \rightarrow 0$ 。

Kim 等^[9]的研究证明, 当训练集存在错误标签噪声时, 使用负训练以一种迂回的方式进行学习, 干净样本的互补标签能带入比噪声样本的互补标签更多的有效信息, 模型会以更快的速度去拟合干净数据。Ma 等^[8]的实验结果也证明, 在远程监督数据集上, 使用正训练时干净数据和噪声数据被模型无差别的进行学习, 置信度都在同步增加。与之相反, 使用负训练时噪声数据的置信度远低于干净数据的置信度。

图 3 为正训练和负训练在噪声数据集 Noisy-TACRED 上的效果对比。经过负训练以后, 噪声数据主要分布在低置信度区间, 干净数据主要分布在中、高置信度区间。

本文采用一个服从正态分布的权重函数来对 NTLoss 进行加权, 该权重函数公式为

$$W(p) = \exp\left(-\frac{(p-\mu)^2}{2\delta^2}\right)^\gamma \quad (3)$$

式中: p 是样本预测概率, μ 、 δ 是权重函数的两个超参数, γ 用于控制权重函数的抑制力度。当 $\gamma \rightarrow 0$ 时, 权重函数的抑制力度会逐渐减小, 最终退化为原始的损失函数。加权以后的负训练损失函数为

$$L_{NT}(f, y^*) = - \sum_{j=1}^C W(p_j) \cdot \bar{y}_j \log(1 - p_j) \quad (4)$$





图 3 Noisy-TACRED 上正训练与负训练效果对比

Fig. 3 Comparison of PT and NT results on Noisy-TACRED

图 4 为加权损失函数的函数曲线, 可见该损失函数低置信度区间和高置信度区间都被拉低, 中部保持不变, 这样将会抑制模型对高、低置信度区间简单干净数据和噪声数据的拟合, 使模型将更多的注意力集中在中部难以区分的数据上。




图 4 加权损失函数曲线

Fig. 4 Curve of weighted loss function

2.2 自适应权重

如图 5 所示, 在相同学习步数下, 模型对不同类的拟合程度是不同的。如果全局使用统一的权

重函数进行加权, 则可能会损害数据分布。在一些拟合相对较慢的类别中, 一些本应该被正常学习的样例会由于整体置信度偏低而受到抑制。





图 5 相同学习步数下不同类的拟合程度

Fig. 5 Fitting degree of different classes under the same number of learning steps


因此, 我们进一步提出一种自适应权重函数, 根据各类数据的拟合情况来动态的调整权重, 自动适应各类的概率分布。假设类 j 的第 i 个样例概率为 $p_j^i \in (0, p_j^h)$, 其中 $p_j^h = \max_{i=1}^{N_j} \{p_j^i\}$ 是第 j 类样例中概率的最大值, N_j 为 j 类样本的个数。第 j 类的自适应权重函数为

$$W_A(p_j) = W(p_j) \cdot \frac{1}{p_j^h} \quad (5)$$

其中 $W(p_j)$ 为全局权重函数, 即式 (3)。

2.3 随机加权

越早进行加权抑制, 则模型对噪声数据的拟合程度就越低, 更多的噪声数据将会被抑制在低置信度区间。但过早施加权重同样会导致模型对仍处于低置信度区间的干净数据欠拟合, 如图 6(a) 所示, 大量干净数据被困于低置信度区间无法得到模型有效的学习。






图 6 训练早期施加权重损失的效果对比

Fig. 6 Comparison of using weighted-loss in early stage

由于模型对于干净数据的拟合速度要比噪声数据更快, 因此在低置信度区间以一个较小的概率随机使一部分数据能够被正常学习, 则既能使干净数据逃离低置信度区间, 又不会让模型过多的拟合噪声数据; 而当训练进入后期, 低置信度区间剩下的主要都是噪声数据, 此时再进行随机正常学习只会加大模型对噪声数据的拟合, 应当加大对低置信度区间数据的抑制。基于此, 本文在式 (5) 的基础上提出了一种随机加权重函数:

$$W_R(p_j) = \begin{cases} 1, & p_j < t_j^p \wedge r_j < T^r \wedge e \leq T^e \\ 0, & p_j < t_j^p \wedge r_j < T^r \wedge e > T^e \\ W_A(p_j), & \text{其他} \end{cases} \quad (6)$$

式中: $t_j^p = T^p \cdot (p_j \setminus p_j^h)$ 是划分低置信度区间的阈值, T^p 是全局阈值, t_j^p 会根据各个类的拟合程度自适应的调整低置信度区间范围; $r_j \in [0, 1]$ 是对应于 p_j 的一个随机数; T^r 为全局阈值; e 为当前训练的 epoch 轮数; T^e 为全局阈值。当 $p_j < t_j^p$ 时, 样本处于低置信度区间, 此时若 $e \leq T^e$ 表示训练处于初期阶段, 为防止干净数据欠拟合, 以 T^r 的概率随机将其权重置为 1, 使其能够被正常学习; 相反, 若 $e > T^e$, 则表示进入训练后期, 此时干净数据已经处于中高置信度区间, 低置信度区间主要为噪声数据, 以 T^r 的概率随机将其权重置为 0, 加大对噪声样本的抑制程度; 其他情况, 则采用 $W_A(p_j)$ 函数进行加权。使用随机加权后最终的损失函数为

$$L_{\text{ANT}}(f, y^*) = - \sum_{j=1}^C W_R(p_j) \cdot \bar{y}_j \log(1 - p_j) \quad (7)$$

由图 6(b) 可以看出使用随机加权损失函数以后, 低置信度区间不再滞留大量干净数据, 而噪声数据则被更多的抑制在了该区间范围内, 分布于中部区间的数据也大幅降低。

3 实验与结果分析

实验分为两个部分, 分别在 NYT-10^[3] 和 TACRED^[21] 数据集上进行。实验采用与 Ma 等^[8] 相同的句子级评估指标, 直接计算单个样例的精度、召回率和 F_1 值。

3.1 基线模型

关系抽取中常用的文本编码器有 CNN^[22]、PCNN^[23]、BiLSTM^[24] 和 BERT^[25], 以及在此基础上的变体 BiLSTM+ATT^[26]、BiLSTM+BERT^[21] 等。

PCNN+SelATT^[12]: 一种包级关系抽取模型, 利用自注意力机制来减轻噪声数据的影响。

PCNN+RA_BAG_ATT^[13]: 一种包级关系抽取模型, 同时在包内和包间使用注意力机制来减轻噪声的影响。

CNN+RL1^[16]: 一种基于强化学习的包级方法。与 CNN+RL2 不同的是, 它们将过滤后的噪声数据重新分配到负样本中。

CNN+RL2^[7]: 一种句子级关系抽取模型, 使用强化学习来联合训练样例选择器和 CNN 分类器。

ARNOR^[6]: 一种基于注意力正则的句子级降噪框架, 迫使模型去学习语义模式而不仅仅是关注实体对, 使模型更具解释性, 并以此来选择可靠的样例。

SENT^[8]: 一种句子级降噪框架, 使用负训练、噪声过滤与重新标记、迭代训练的方法, 有效地将噪声数据从训练数据中分离, 并重新标记用以训练。它是目前句子级别最先进的方法。

3.2 实验细节

实验中, 除 ANTLoss 以外的参数均保持与 SENT 源码一致, 仅对 ANTLoss 参数进行网格搜索调参, 具体参数设置如表 1 所示。

表 1 方法参数

Table 1 Method parameters

参数	值
μ	0.4
δ	0.5
γ	1
T^p	0.35
T^r	0.25
T^e	7

在具体实现中, 本文在每一次 Epoch 训练结束后同步更新 p_j^h , 作为下一轮 Epoch 训练中损失函数自适应调整的参数。因此, ANTLoss 至少需要经过一个 Epoch 之后才能生效。由于采用前一轮历史 p_j^h 来近似当前轮的最大值, 可能出现缩放后权重大于 1 的情况, 对此我们将大于 1 的权重置为 1。

在消融实验中, 对于没有使用随机加权的损失函数需要经过 7 个 Epoch 的预热训练, 待干净数据大部分进入中、高置信度区间后才开始生效。

3.3 NYT-10 上的效果

第 1 部分实验在 NYT-10 上开展, 以验证本方法在句子级远程监督数据集上的有效性。NYT-10 最早是由 Riedle 等提出一个远程监督数据集,

在之后的研究中被广泛使用。Jia 等^[6]在其基础上进行人工精标,发布了一个句子级的关系抽取测试集以及降噪评估测试集。

3.3.1 句子级评估

表 2 给出了使用 ANTLoss 以后的 SENT 模型

与其他基线模型在句子级评估上的效果对比,我们将模型运行了 3 次,计算均值与标准差。从表 2 可以看出:本文模型相比其他方法准确率提升了 5.12%, F_1 提升了 2.36%,说明本方法在分类性能提升上的有效性。

表 2 NYT-10 测试集上的句子级评估结果

Table 2 Sentence level evaluation results on NYT-10 test set

%

方法	验证集			测试集		
	准确率	召回率	F_1	准确率	召回率	F_1
CNN	38.32	65.22	48.28	35.75	64.54	46.01
PCNN	36.09	63.66	46.07	36.06	64.86	46.35
BiLSTM	36.71	66.46	47.29	35.52	67.41	46.53
BiLSTM+ATT	37.59	64.91	47.61	34.93	65.18	45.48
BERT	34.78	65.17	45.35	36.19	70.44	47.81
BiLSTM+BERT	36.09	73.17	48.34	33.23	72.70	45.61
PCNN+SelATT	46.01	30.43	36.64	45.41	30.03	36.15
PCNN+RA_BAG_ATT	49.84	46.90	48.33	56.76	50.60	53.50
CNN+RL1	37.71	52.66	43.95	39.41	61.61	48.07
CNN+RL2	40.00	59.17	47.73	40.23	63.78	49.34
ARNOR	62.45	58.51	60.36	65.23	56.79	60.90
SENT (BiLSTM)	66.71±0.30	57.27±0.30	61.63±0.29	71.22±0.58	59.75±0.62	64.99±0.34
SENT (BiLSTM) +ANTLoss	72.04±0.56	57.06±0.69	63.68±0.29	76.34±0.68	60.26±0.29	67.35±0.19

3.3.2 降噪效果

本文通过直接提升模型降噪性能进而间接提升模型的关系抽取性能,因此降噪效果是衡量该方法好坏的直接指标。降噪结果如表 3 和图 7。

表 3 NYT-10 降噪测试集上的评估结果

Table 3 Evaluation results on nyt-10 denoise test set

%

方法	准确率	召回率	F_1
CNN+RL	40.58	96.31	57.10
ARNOR	76.37	68.13	72.02
SENT (BiLSTM)	80.00	88.46	84.02
SENT (BiLSTM)+ANTLoss	80.76	88.78	84.58




图 7 各迭代次数模型降噪性能比较

Fig. 7 Comparison of noise reduction performance of each iteration model

根据表 3,文中方法在 F_1 上提升了 0.58%。通过分析降噪测试集各类的降噪效果,发现数据量较大的类别中 F_1 已经达到 0.9 以上,而数据量较少的类别 F_1 普遍更低,从概率分布可发现该类

别样本通常整体处于欠拟合状态,并不适合通过加权抑制来进行降噪处理。因此,影响 F_1 值的是数据量较少的类别,加上 ANTLoss 以后有所提升,但是整体提升空间不大。

如图 7 所示,从模型各迭代训练次数的降噪效果来看,SENT 的方法需要经过 14 次迭代训练才能达到 0.8 以上,且过程中有较大波动;而文中方法仅需经过 2 次迭代,速度提升 7 倍,效果也更稳定。因为 ANTLoss 在将更多的噪声数据压制在低置信度区间的同时拉开了噪声数据和干净数据之间的距离,降低了阈值设置的敏感度,模型在收敛速度得到提升的同时性能也更为稳定。

3.4 Noisy-TACRED 上的效果

第 2 部分实验在斯坦福大学开源的一套人工精标的关系抽取数据集 TACRED 上开展,参照 Ma 等^[8]的构造方法,合成了一个包含 30% 噪声的 Noisy-TACRED 数据集,以更直观的展示本方法各组件的降噪效果。

由于本框架与文本编码模型无关,为更明显的体现本方法改进后的效果,此处选用关系抽取中最为经典的 PCNN 模型作为编码器,在初始化 NT 训练中对 ANTLoss 各模块进行消融实验。

3.4.1 P@LastN 准确率

类似之前工作中所使用的 P@N 指标,本文采用 P@LastN 来计算概率最小的 N 个样本中模型的降噪准确度。

如图8所示,当训练轮数超过12轮以后,原始的SENT方法降噪精度迅速下降,在P@Last-500中,ANTLoss损失函数基本能稳定不变,在P@Last1000与P@Last2000中下降的速度也要明显慢于原始方法,可见ANTLoss可以有效提升模型对噪声数据的抗拟合性能,将更多的噪声抑制在低置信度区间。从图中还可以观察到,随着样本量增加,前3条曲线均有不同程度的波动,ANTLoss相较更为稳定。

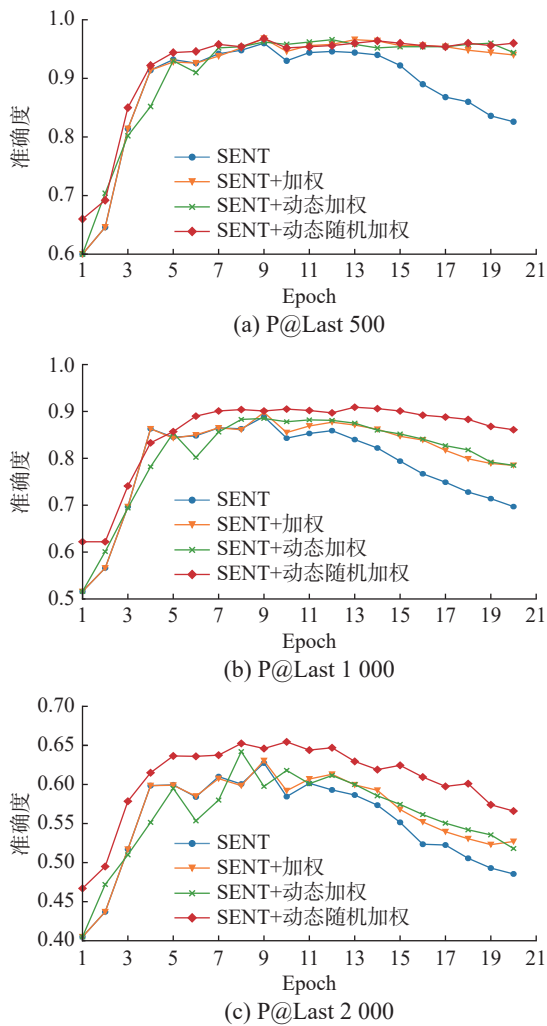


图8 P@LastN 曲线
Fig. 8 Curve of P@LastN

如表4所示,分别统计了500、1000、2000个样本中模型降噪准确率的最大值并求其均值,ANTLoss各项指标均较先前的方法有所提升,其中均值较原始SENT方法提升1.5%。

表4 P@LastN 准确率对比
Table 4 P@LastN accuracy comparison %

方法	500	1000	2000	均值
SENT(PCNN)	96.00	89.90	67.75	84.55
+加权	96.80	89.80	68.05	84.88

续表4

方法	500	1000	2000	均值
+动态加权	96.60	88.50	69.20	84.76
+动态随机加权	96.80	90.90	70.45	86.05

3.4.2 固定阈值下的降噪效果

在真实远程监督数据集上,由于不清楚噪声数据的具体数据量,往往通过设置阈值的方式来过滤噪声数据。图9给出了随着模型迭代轮数的增加,在35%阈值下过滤噪声的查准率、召回率以及 F_1 。




图9 固定阈值下降噪效果曲线
Fig. 9 Curve of denoising result with fixed threshold

从图9可以看出,使用加权损失函数以后过滤噪声的召回率在训练后期相较于原始方法大幅度提升,查准率也略有提升。由于ANTLoss采用了随机加权方法,在训练前期干净数据能快速逃离阈值过滤区间,因此前期降噪查准率提升更为迅速;而在训练后期噪声数据权重被随机置为0,大幅度降低了模型对噪声数据的拟合程度,使得更多的噪声数据能滞留于阈值过滤区间之内,因此后期召回率下降幅度减小。

表 5 给出了 35% 阈值下 4 种方法降噪 F_1 的最大值。从表 5 可以看出: 随着损失函数的逐步优化, 降噪性能逐步提升, 最终 ANTLoss 相较于原始方法提升了 3.28%。

表 5 固定阈值下降噪效果对比

方法	F_1	%
SENT(PCNN)	71.92	
+加权	72.52	
+动态加权	74.70	
+动态随机加权	75.20	

3.4.3 噪声样本和干净样本的分离率

噪声与干净数据分离率越大, 则降噪阈值敏感度越低, 模型降噪性能越稳定。首先, 分别计算所有噪声和干净数据的平均置信度; 然后, 计算其差值作为噪声和干净数据的分离率来对模型进行评估, 实验结果如图 10 所示。




图 10 噪声分离率曲线

Fig. 10 Curve of noise separation rate

从图 10 可以看出, 本文方法对于干净数据的平均置信度有所提升, 同时大幅减小了噪声数据的平均置信度。由于采用了随机加权损失, ANTLoss 从训练的第 2 个 epoch 就开始生效, 而未使用随机加权的损失函数需要经过 7 个 epoch 的预热训练才能开始生效, 且后期噪声抗拟合性能相对更弱。最终的 ANTLoss 噪声分离率曲线稳定且完全包裹住了前面的方法。

表 6 统计了各方法噪声分离率的最大值, 容易看出噪声分离率随着方法优化在逐步提升, 最终相较原始模型提升了 11.51%, 说明了本文方法在提升噪声分离率上的有效性。

表 6 噪声分离率效果对比

方法	分离率	%
SENT(PCNN)	45.06	
+加权	47.61	
+动态加权	48.41	
+动态随机加权	56.57	

4 结束语

本文通过对干净、噪声样本概率分布进行分析, 提出了一种自适应加权损失函数, 可以进一步将噪声数据抑制在低概率区间, 并有效地拉开了噪声数据和干净数据之间的距离。基于此, 提出了一种句子级远程监督关系抽取方法, 用于解决远程监督数据集中的错误标签噪声问题。实验结果表明, 本方法在句子级远程监督关系抽取的降噪和分类性能上相较之前的方法都有所提升。

参考文献:

- [1] 张涛, 贾真, 李天瑞, 等. 基于知识库的开放领域问答系统 [J]. 智能系统学报, 2018, 13(4): 557-563.
ZHANG Tao, JIA Zhen, LI Tianrui, et al. Open-domain question-answering system based on large-scale knowledge base[J]. CAAI transactions on intelligent systems, 2018, 13(4): 557-563.
- [2] MINTZ M, BILLS S, SNOW R, et al. Distant supervision for relation extraction without labeled data[C]//Conference of Association for Computational Linguistics. Stroudsburg: ACL, 2009: 1003-1011.
- [3] RIEDEL S, YAO Limin, MCCALLUM A. Modeling relations and their mentions without labeled text[C]//Proceedings of the 2010 European Conference on Machine Learning and Knowledge Discovery in Databases-Volume Part III. New York: ACM, 2010: 148-163.

- [4] YAO Xuchen, VAN DURME B. Information extraction over structured data: question answering with freebase[C]//Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). Stroudsburg: Association for Computational Linguistics, 2014: 956–966.
- [5] XU Kun, REDDY S, FENG Yansong, et al. Question answering on freebase via relation extraction and textual evidence[C]//Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). Stroudsburg: Association for Computational Linguistics, 2016: 2326–2336.
- [6] JIA Wei, DAI Dai, XIAO Xinyan, et al. ARNOR: attention regularization based noise reduction for distant supervision relation classification[C]//Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. Stroudsburg: Association for Computational Linguistics, 2019: 1399–1408.
- [7] FENG Jun, HUANG Minlie, ZHAO Li, et al. Reinforcement learning for relation classification from noisy data[C]//Proceedings of the AAAI Conference on Artificial Intelligence. New Orleans: AAAI, 2018, 32(1): 5779–5786.
- [8] MA Ruotian, GUI Tao, LI Linyang, et al. SENT: sentence-level distant relation extraction via negative training[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume 1: Long Papers). Stroudsburg: Association for Computational Linguistics, 2021: 6201–6213.
- [9] KIM Y, YIM J, YUN J, et al. NLNL: negative learning for noisy labels[C]//2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019: 101–110.
- [10] HOFFMANN R, ZHANG Congle, LING Xiao, et al. Knowledge-based weak supervision for information extraction of overlapping relations[C]//Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies-Volume 1. Portland: ACM, 2011: 541–550.
- [11] SURDEANU M, TIBSHIRANI J, NALLAPATI R, et al. Multi-instance multi-label learning for relation extraction[C]//Proceedings of the 2012 Joint Conference on Empirical Methods in Natural Language Processing and Computational Natural Language Learning. Jeju Island: ACM, 2012: 455–465.
- [12] LIN Yankai, SHEN Shiqi, LIU Zhiyuan, et al. Neural relation extraction with selective attention over instances[C]//Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). Stroudsburg: Association for Computational Linguistics, 2016: 2124–2133.
- [13] YE Zhixiu, LING Zhenhua. Distant supervision relation extraction with intra-bag and inter-bag attentions[C]//Proceedings of the 2019 Conference of the North. Stroudsburg: Association for Computational Linguistics, 2019: 2810–2819.
- [14] LI Yang, LONG Guodong, SHEN Tao, et al. Self-attention enhanced selective gate with entity-aware embedding for distantly supervised relation extraction[C]//Proceedings of the AAAI Conference on Artificial Intelligence. New York: AAAI, 2020, 34(5): 8269–8276.
- [15] LIU Tianyu, WANG Kexiang, CHANG Baobao, et al. A soft-label method for noise-tolerant distantly supervised relation extraction[C]//Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: Association for Computational Linguistics, 2017: 1790–1795.
- [16] QIN Pengda, XU Weiran, WANG W Y. Robust distant supervision relation extraction via deep reinforcement learning[C]//Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). Stroudsburg: Association for Computational Linguistics, 2018: 2137–2147.
- [17] SHANG Yuming, HUANG Heyan, MAO Xianling, et al. Are noisy sentences useless for distant supervised relation extraction? [C]//Proceedings of the AAAI Conference on Artificial Intelligence. New York: AAAI, 2020, 34(5): 8799–8806.
- [18] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]//2017 IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 2999–3007.
- [19] TAN Qingyu, HE Ruidan, BING Lidong, et al. Document-level relation extraction with adaptive focal loss and knowledge distillation[C]//Findings of the Association for Computational Linguistics: ACL 2022. Stroudsburg: Association for Computational Linguistics, 2022: 1–10.
- [20] 彭正阳, 吕立, 于碧辉. 基于动态损失函数的远程监督关系抽取 [J]. 小型微型计算机系统, 2021, 42(2): 251–255.
PENG Zhengyang, LYV Li, YU Bihui. Dynamic loss function for distant supervision relation extraction[J]. Journal of Chinese computer systems, 2021, 42(2): 251–255.
- [21] ZHANG Yuhao, ZHONG V, CHEN Danqi, 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: Association for Computational Linguistics, 2017: 35–45.
- [22] ZENG Daojian, LIU Kang, LAI Siwei, et al. Relation

- classification via convolutional deep neural network[C]//COLING 2014—25th International Conference on Computational Linguistics, Proceedings of COLING 2014: Technical Papers. Stroudsburg: Association for Computational Linguistics, 2014: 2335–2344.
- [23] ZENG Daojian, LIU Kang, CHEN Yubo, et al. Distant supervision for relation extraction via piecewise convolutional neural networks[C]//Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: Association for Computational Linguistics, 2015: 1753–1762.
- [24] ZHANG S, ZHENG D, HU X, et al. Bidirectional long short-term memory networks for relation classification[C]//Proceedings of the 29th Pacific Asia Conference on Language, Information and Computation. Stroudsburg: Association for Computational Linguistics, 2015: 73–78.
- [25] DEVLIN J, CHANG Mingwei, LEE K, et al. BERT: pre-training of deep bidirectional transformers for language understanding[EB/OL]. (2018–10–11)[2022–05–23]. <http://arxiv.org/abs/1810.04805>.
- [26] 张勇, 高大林, 巩敦卫, 等. 用于关系抽取的注意力图长短时记忆神经网络 [J]. 智能系统学报, 2021, 16(3): 518–527.
- ZHANG Yong, GAO Dalin, GONG Dunwei, et al. Attention graph long short-term memory neural network for re-

lation extraction[J]. CAAI transactions on intelligent systems, 2021, 16(3): 518–527.


作者简介:



胡峰, 博士, 教授, 主要研究方向为粗糙集、粒计算、数据挖掘。主持和参与国家自然科学基金项目 4 项, 参与科技部重点研发计划项目 3 项, 作为参与者获吴文俊人工智能科学技术奖、重庆市自然科学奖各 1 项, 发表学术论文 40 余篇。E-mail: hufeng@cqupt.edu.cn。



杨新瑞, 硕士研究生, 主要研究方向为自然语言处理、信息抽取、数据挖掘。E-mail: 1158737962@qq.com。



汤成富, 硕士研究生, 主要研究方向为计算机视觉、图像识别、数据挖掘。E-mail: tangcfmail@163.com。

机器人科普教育进校园系列活动

2024 年 5 月 22 日, 由中国人工智能学会(CAAI)主办, CAAI 青年工委委员会承办的“机器人科普教育进校园系列活动”即将开启新的一期。CAAI 青年工作委员会的相关委员同志、湖北第二师范学院物理与机电工程学院机器人 STEAM 教育研究所的科技志愿者们将走进湖北省仙桃市“沙湖列宁小学”旧址上的乡村学校——仙桃市沙湖小学, 服务乡村教育、为乡村振兴出一份力。

本期活动, 科技志愿者们将在讲解机器人的起源、发展以及各种应用等科普知识的基础上, 带领小朋友们通过自己动手造就机器人小车的“体魄”、赋予机器人小车“灵魂”, 感受科学技术带来的奇特体验, 勉励小朋友们从小树立爱科学、学科学、用科学的意识。