

一种循环神经网络的词义消歧方法

张春祥¹, 周雪松², 高雪瑶²

(1. 哈尔滨理工大学 软件与微电子学院, 哈尔滨 150080; 2. 哈尔滨理工大学 计算机科学与技术学院, 哈尔滨 150080)

摘 要: 词义消歧是自然语言处理领域中的一个重要研究问题。针对汉语一词多义现象, 结合上下文语境, 采用循环神经网络(Recurrent Neural Networks, RNN) 来确定歧义词汇的真实含义。以目标歧义词汇为中心, 提取其左右 4 个邻接的词汇单元。从中抽取词形、词性和语义类作为消歧特征。以消歧特征为基础, 结合循环神经网络来构建词义消歧分类器。利用 SemEval-2007: Task#5 的训练语料和哈尔滨工业大学语义标注语料来优化 RNN 的参数。使用 SemEval-2007: Task#5 的测试语料对词义消歧分类器进行测试。实验结果表明: 所提出的方法能够提高词义消歧的准确率。

关键词: 词义消歧; 自然语言处理; 循环神经网络; 消歧特征

DOI: 10.15938/j.jhust.2020.01.012

中图分类号: TP391.2 文献标志码: A 文章编号: 1007-2683(2020)01-0080-06

A Method of Word Sense Disambiguation with Recurrent Neural Networks

ZHANG Chun-xiang¹, ZHOU Xue-song², GAO Xue-yao²

(1. School of Software and Microelectronics, Harbin University of Science and Technology, Harbin 150080, China;

2. School of Computer Science and Technology, Harbin University of Science and Technology, Harbin 150080, China)

Abstract: Word sense disambiguation is an important research problem in natural language processing field. For the phenomenon that a Chinese word has many senses, recurrent neural network (RNN) is used to determine true meaning of ambiguous word with its context. Target ambiguous word is viewed as center and its four adjacent word units are extracted. Word, part-of-speech and semantic categories are extracted as disambiguation features. Based on disambiguation features, recurrent neural network is used to construct word sense disambiguation classifier. Training corpus in SemEval-2007: Task#5 and semantic annotation corpus in Harbin Institute of Technology are used to optimize parameters of RNN. Test corpus in SemEval-2007: Task#5 is applied to test word sense disambiguation classifier. Experimental results show that the proposed method can improve accuracy of word sense disambiguation.

Keywords: word sense disambiguation; natural language processing; recurrent neural network; disambiguation features

收稿日期: 2018-04-20

基金项目: 国家自然科学基金(61502124, 60903082); 中国博士后科学基金(2014M560249); 黑龙江省自然科学基金(F2015041, F201420); 黑龙江省普通高校基本科研业务费专项资金(LGYC2018JC014)。

作者简介: 张春祥(1974—), 男, 博士, 教授;

周雪松(1996—), 女, 硕士研究生。

通信作者: 高雪瑶(1979—), 女, 博士, 副教授, E-mail: xueyao_gao@163.com.

0 引言

词义消歧是自然语言处理领域中的基础性研究问题。同时,也是机器翻译和机器理解中的核心步骤。鹿文鹏根据依存句法分析结果来提取歧义词汇的依存约束集合。从 WordNet 中找出歧义词汇各个词义的代表词。根据词义代表词在依存约束集合中的依存适配度来选择正确的词义^[1]。鹿文鹏等^[2]利用文本领域关联词和句子上下文词来构建消歧图。利用领域知识来调整消歧图。同时,使用改进的图评分标准对消歧图中的各个词义结点的重要程度进行打分。杨陟卓等^[3]运用语言模型来优化有监督消歧模型。充分利用有监督消歧模型和语言模型来确定歧义词汇的真实含义。在训练语料不足的情况下,这种方法可以有效地改善词义消歧的效果。王少楠等^[4]将上下文语境中具有明确含义的实词作为输入。在上下文语境中,获取可以表示歧义词汇语义的其它特征。最后,利用贝叶斯概率模型将这两种信息结合起来,共同实现歧义词汇的语义表示和归纳。实验结果表明:这种方法可以得到更好的语义表示和归纳效果。唐共波等^[5]将多义词的上下文作为消歧特征,以形成特征向量。通过计算多义词词向量与特征向量之间的相似度来进行词义消歧。该方法可以大大地减少词义消歧模型的时间复杂度。杨陟卓等^[3]设计并实现了一种基于模拟退火的词义消歧方法,能够自动估计各种知识类型的关系权重,并优化各种知识对消歧效果的影响。这种方法有效地克服了数据稀疏和知识获取的瓶颈。杨振景等^[6]提取歧义词汇上下文中的局部词、局部词性以及局部词和词性对作为消歧特征,并对这三种特征赋予不同的权重。同时,利用支持向量机模型来确定歧义词汇的真实含义。范弘屹等^[7]给出了一种改进的语义相似度计算方法。在原有方法的基础上,考虑 HowNet 中义原的深度和密度对词语相似度的影响。挖掘义原之间的关系,改进原有的计算方法。张健立等^[8]利用 WordNet 中的语义关系来构建语义关系图。根据歧义词汇与其上下文之间的关联度,来确定它的最佳含义。Zhu^[9]提出了一种基于冯诺依曼核的半监督词义消歧方法。利用词与词之间的共现来定义图。根据有标注和无标注训练数据在图中的传播过程来计算术语之间的语义相似度。然后,根据语义相似度来构造冯诺依曼核。Huang 等^[10]将语义分析视为多个语义序参数竞争的过程,提出了一种基于改进协同神经网络并融入词义信息的角色标注模型。Abualhaija 等^[12]以

遗传模拟退火算法和蚁群算法为基础,提出了一种蜂群算法来解决词义消歧问题。Hung 等^[13]提出了一种基于口语词文档的词义消歧方法。首先构建了情感词汇网词典,然后利用所构建的词典进行词义消歧。史兆鹏等^[14]从依存句法分析结果中提取歧义词汇及其上下文的词性、依存结构和依存词。构造歧义词汇语义类的权值函数,选择权值最大的语义类进行消歧。高璐等^[15]提出了一种利用知网实例库和知网关系进行词义消歧的算法。钱涛等^[16]给出了一种基于超图的词义消歧模型。利用词汇链找到歧义词汇与上下文词汇之间的高阶语义关系。将上下文词汇作为结点,利用词汇链所找到的超边来构建超图。利用基于最大密度的超图谱聚类算法来确定歧义词汇的含义。任海英等^[17]提出了一种基于维基百科的多策略词义消歧方法。设计了类别一致性、内容相关性和词义重要程度三个指标。利用二次消歧方法来确定歧义词汇的真实含义。刘峤等^[18]提出了一种基于语义一致性的集成实体链接算法,能够更好地利用知识库中实体之间的结构化语义关系,提高了算法对概念相似实体的区分度。许坤等^[19]利用语料库来构建从实体到知识库的映射,对谓词进行消歧。然后,将自然语言问句转化为计算机可理解的结构化查询语句。杨安利等^[20]用无标注文本来构建词向量模型,结合特定领域的关键词信息,提出了一种新的词义消歧方法。

本文以歧义词汇为中心,选取它左右两侧的 4 个邻接词汇单元中的词形、词性和语义类作为消歧特征,利用循环神经网络来确定它的正确语义。

1 消歧特征的选择

歧义词汇的语义类别是由其上下文环境所决定的。在歧义词汇的上下文中,包含了很多用于确定歧义词汇语义的语言学知识。要想确定歧义词汇的真实含义,就要从其上下文中挖掘相关的信息,这就是所谓的消歧特征提取。特征选取的方法不同,词义消歧的结果会不同,这将会直接影响到词义消歧的效果。

以歧义词汇为中心,选取其左右邻接的 4 个词汇单元。从这 4 个词汇单元中,分别提取其词形、词性和语义类 3 种消歧特征。以包含歧义词汇“镜头”的汉语句子为例,其消歧特征的提取过程为:

汉语句子:另一个镜头是周总理向灾区群众讲话。

分词结果:另一个镜头是周总理向灾区群众讲话。

词性标注结果: 另/r 一个/m 镜头/n 是/v 周/nh 总理/n 向/p 灾区/n 群众/n 讲话/v。

语义类标注结果: 另/r/E 一个/m/D 镜头/n/D 是/v/J 周/nh/-1 总理/n/A 向/p/K 灾区/n/C 群众/n/A 讲话/v/H。

消歧特征的提取过程如图1所示。其中, W 表示词形; P 表示词性; S 表示语义类。Unit_{L1} 和 Unit_{L2} 分别表示歧义词汇左边邻接的两个词汇单元。Unit_{R1} 和 Unit_{R2} 分别表示歧义词汇右边邻接的两个词汇单元。歧义词汇“镜头”左侧的两个词汇单元分别为“另/r/E”和“一个/m/D”。此处, r 表示代词; m 表示数词“另”所属的语义大类为 E “一个”所属的语义大类为 D 。歧义词汇“镜头”右侧的两个词汇单元分别为“是/v/J”和“周/nh/-1”。此处, v 表示动词; nh 表示姓氏词“是”所属的语义大类为 J “周”所属的语义大类为 -1 。从这4个词汇单元中, 分别提取词形、词性和语义类作为消歧特征。




图1 词义消歧特征的提取过程

Fig.1 Extraction of WSD Features

2 基于循环神经网络的语义分类

本文选用循环神经网络对歧义词汇进行消歧。基于 RNN 的消歧框架主要分为数据预处理和分类消歧两个部分。基于 RNN 的词义消歧框架如图2所示。




图2 基于循环神经网络的词义消歧框架

Fig.2 WSD Framework Based on RNN

在数据预处理部分,将训练数据转换为 RNN 所能接受的标准输入数据。在传统的数据处理中,采用了独热编码 (one-hot) 方法。采用寄存器对不同的状态进行标识。在任意时刻,寄存器只有一位设置为 1,其余位均设置为 0。使用这种方法所得到的特征向量是非常稀疏和冗长的。为了解决这个问题,引入了 Embedding 层来对输入数据进行处理。将所提取的消歧特征转化为一个由浮点数表示的特征矩阵。在特征矩阵中,每一列表示一个词汇单元的特征向量。所得到的数据是稠密的,能更好地表示特征信息。使用公式(1)来计算词汇单元的各个消歧特征的 Embedding 向量。

$$r_m = M \cdot v_m \quad (1)$$

其中: 矩阵 $M \in R^{d \times V}$ 是一个随机初始化的大规模浮点数矩阵; d 为 Embedding 向量的维数; V 为消歧词窗所包含的词汇单元数目; v_m 是词汇单元的消歧特征的 one-hot 表示。在 Embedding 层中,采用点乘运算来求解消歧特征所对应的 Embedding 向量 r_m 。

在汉语句子 C 中,歧义词汇 w 的人工标注语义类为 S 。歧义词汇 w 左侧第二个词汇单元为 Unit_{L2} = (W_{L2}, P_{L2}, S_{L2}); 左侧第一个词汇单元为 Unit_{L1} = (W_{L1}, P_{L1}, S_{L1}); 右侧第一个词汇单元为 Unit_{R1} = (W_{R1}, P_{R1}, S_{R1}); 右侧第二个词汇单元为 Unit_{R2} = (W_{R2}, P_{R2}, S_{R2})。对于词汇单元 Unit_{L2}, 计算 W_{L2} 的独热编码; 然后利用公式(1)来获取它所对应的 Embedding 向量 $F_{W_{L2}}$ 。计算 P_{L2} 的独热编码; 然后利用公式(1)来获取它所对应的 Embedding 向量 $F_{P_{L2}}$ 。计算 S_{L2} 的独热编码; 然后利用公式(1)来获取它所对应的 Embedding 向量 $F_{S_{L2}}$ 。连接 $F_{W_{L2}}, F_{P_{L2}}$ 和 $F_{S_{L2}}$, 形成特征向量 F_{L2} 。同理,可以获得 Unit_{L1} 的特征向量 F_{L1} 、Unit_{R1} 的特征向量 F_{R1} 和 Unit_{R2} 的特征向量 F_{R2} 。以特征向量 F_{L2}, F_{L1}, F_{R1} 和 F_{R2} 为基础, 构造特征矩阵 $Feature = \{F_{L2}, F_{L1}, F_{R1}, F_{R2}\}$ 。使用特征矩阵 $Feature$ 和人工标注语义类 S 来训练 RNN, 以获得优化的模型参数。

RNN 是一种利用序列信息来进行数据处理的模型^[2]。其特点是: 能够保存当前时刻的上下文状态; 在上下隐藏层的结点之间, 存在连接边。在 RNN 中, 包括输入层、隐藏层和输出层。

输入层接受特征矩阵 $Feature$ 。将特征向量 $F_{L2}, F_{L1}, F_{R1}, F_{R2}$ 分别赋给输入层所对应的结点。在隐藏层中, 神经元是相对独立的。隐藏层的层数是由特征向量的个数决定的。在 t 时刻, 隐藏层结点的状态是由 t 时刻的输入层结点所接受的特征向量和 $t-1$ 时刻的隐藏层结点状态共同决定的。将隐藏层的计算结果先送入全链接层, 然后再送入输出

层的 *SoftMax* 函数。其目的是: 使 *SoftMax* 函数的输入和输出维数相同。 *SoftMax* 函数根据 t 时刻输入的特征向量和 $t-1$ 时刻隐藏层结点状态来计算 t 时刻的语义类概率分布向量。

图中 S'_{t1} 表示 t_1 时刻, 语义类概率分布向量中, 最大的概率所对应的语义类; S'_{ti} 表示 t_i 时刻的语义类概率分布向量中, 最大的概率所对应的语义类。 *SoftMax* 输出结果是一个向量。其维数为语义类的数目。若歧义词汇 w 有 n 种语义类别 $S_1, S_2, \dots, S_n$, 则 *SoftMax* 输出一个 n 维的语义类概率分布向量 $\{P(S_1), P(S_2), \dots, P(S_n)\}$ 。在输出向量中, 各个分量表示歧义词汇在各个语义类下的概率分布。在输出层中, 最后一个结点的 *SoftMax* 函数输出语义类概率分布向量。在向量中, 最大概率值 $P(S_i)$ 所对应的语义类 S_i , 就是 RNN 计算的歧义词汇的语义类。

在图 2 中, U 表示输入层与隐藏层之间的连接权值矩阵; D 表示 $t-1$ 时刻的隐藏层与 t 时刻的隐藏层之间的连接权值矩阵; V 表示隐藏层与输出层之间的连接权值矩阵。矩阵 U, D 和 V 是 RNN 的模型参数。在模型训练之前, 将矩阵 U, D 和 V 随机初始化为很小的数值。

3 基于循环神经网络词义消歧模型的训练

RNN 是一种基于时间维度的模型。隐藏层可以在时间维度上进行展开。此处, 设置 RNN 的隐藏层层数为 4。基于时间维度展开的 RNN 模型如图 3 所示。




图 3 RNN 沿时间展开

Fig. 3 RNN unfolds over time

在图 3 中, $Feature$ 表示特征矩阵; F_t 表示 t 时刻输入层结点所接受的特征向量; A_t 是 t 时刻隐藏层结点的状态; O_t 是 t 时刻所输出的语义类概率分布向量; S'_t 是 t 时刻 RNN 所输出的歧义词汇的语义类。其中, $t=1, 2, 3, 4$ 。RNN 的训练过程包括前向传播过程和反向传播过程。

1) 前向传播过程。

在前向传播过程中, 根据 t 时刻所接受的特征向量 F_t 和 $t-1$ 时刻隐藏层结点的状态 A_{t-1} , 来计算 t 时刻的语义类概率分布向量 $O_t = \{P(S_1), P(S_2), \dots, P(S_n)\}$ 。整个传播过程是自底向上进行的, 具体步骤如下所示。

① 输入特征矩阵 $Feature = \{F_{12}, F_{L1}, F_{R1}, F_{R2}\}$, F_t 为 t 时刻输入层所接受的向量, 赋值 $F_1 = F_{12}, F_2 = F_{L1}, F_3 = F_{R1}, F_4 = F_{R2}$;

② for($t=1$; $t \leq 4$; $t++$)

{

a) 将隐藏层结点状态初始化为 0。隐藏层的结点接受特征向量 F_t 后, 更新隐藏层的结点状态 A_t :

$$A_t = ReLU(UF_t + DA_{t-1}) \quad (2)$$

其中, $ReLU$ 为激活函数, 其形式:

$$ReLU(x) = \begin{cases} x, & \text{if } x > 0 \\ 0, & \text{if } x \leq 0 \end{cases} \quad (3)$$

b) 计算 t 时刻输出层结点的语义类概率分布向量 O_t :

$$O_t = \text{SoftMax}(VA_t) = \frac{e^{-VA_t}}{\sum_k e^{-VA_{tk}}} \quad (4)$$

其中 k 表示第 k 种语义类。 $k=1, 2, \dots, n$ 。

c) 从 t 时刻语义类概率分布向量 $O_t = \{P(S_1), P(S_2), \dots, P(S_n)\}$ 中, 选取概率值最大的语义类别 S'_t :

$$S'_t = \max\{P(S_1), P(S_2), \dots, P(S_n)\} \quad (5)$$

d) S'_t 就是 t 时刻 RNN 输出的歧义词汇的语义类别。

2) 反向传播过程。

在反向传播过程中, 采用基于时间的反向传播方法(Back Propagation Through Time, BPTT) 来更新 RNN 的参数。在反向传播过程中, t 时刻 RNN 参数的计算要接受来自 $t+1$ 时刻的反馈。采用交叉熵损失函数来计算歧义词汇 w 的人工标注语义类 S 和 t 时刻 RNN 输出的语义类 S'_t 之间的损失值, 以判断是否结束 RNN 模型的训练过程。具体训练过程如下:

① 计算 t 时刻 RNN 输出的语义类 S'_t 与人工标注语义类 S 之间的误差, 即

$$E_t(S, S'_t) = -S \ln S'_t \quad (6)$$

② 计算四层隐藏层的误差总和 $E(S, S'_t)$, 即

$$E(S, S'_t) = \sum_{t=1}^4 E_t(S, S'_t) = -\sum_{t=1}^4 S \ln S'_t \quad (7)$$

③ 利用公式(7)和(8)来更新参数 $\theta = \{U, V, D\}$ 。

$$\frac{\partial E(S, S_i)}{\partial \theta} = \sum_{t=1}^4 \frac{\partial E_t(S, S_i)}{\partial \theta} = \sum_{t=1}^4 \frac{\partial E_t(S, S_i)}{\partial S_i'} \cdot \frac{\partial S_i'}{\partial \theta} \quad (8)$$

$$\theta_{\text{new}} = \theta_{\text{old}} - \eta \frac{\partial E(S, S_i)}{\partial \theta} \quad (9)$$

④循环执行步骤①②③来更新参数 θ 。如果参数 θ 收敛,那么 RNN 训练结束。

基于 RNN 的词义消歧过程为:将测试数据转换为特征矩阵。利用前向传播过程来计算歧义词汇的语义类别。将特征矩阵中的特征向量分别赋给 RNN 模型输入层的接受向量 F_t ($t = 1, 2, 3, 4$)。使用优化后的权值矩阵 U, V, D 作为 RNN 的参数。在隐藏层中,利用式(1)来计算结点的状态。在输出层中,利用式(4)来计算语义类概率分布向量。取最后一个结点的输出向量 $O_4 = \{P(S_1), P(S_2), \dots, P(S_n)\}$ 作为语义类概率分布向量。在语义类概率分布向量 O_4 中,根据式(5)来选择最大概率值 $P(S_i)$ 。 S_i 就是 RNN 计算所得到的歧义词汇的语义类别。

4 实验

本文将 SemEval-2007: Task#5 的训练语料和测试语料作为训练数据和测试数据。其中, SemEval-2007: Task#5 是 ACL2007 的一个组成部分,即 SemEval-2007 国际语义评测的中英文词汇任务(task#5 multilingual Chinese English lexical sample task)。该任务共包含 40 个歧义词汇。从中选取常用的 10 个歧义词汇。其中,含有两种语义类的歧义词汇有 5 个,分别为“表面”、“儿女”、“气象”、“望”、“中医”;含有 3 种语义类的歧义词汇有 5 个,分别为“补”、“成立”、“赶”、“日子”、“长城”。

为了度量本文所提出方法的性能,共进行了两组实验。在第 1 组实验中,选取歧义词汇左右邻接的两个词汇单元的词形作为消歧特征,采用贝叶斯(Bayes)分类器来确定歧义词汇的语义。使用 SemEval-2007: Task#5 的训练语料对贝叶斯分类器进行训练。利用优化后的贝叶斯分类器对 SemEval-2007: Task#5 的测试语料进行词义消歧。在第 2 组实验中,选取歧义词汇左右邻接的四个词汇单元的词形、词性和语义类作为消歧特征,利用 RNN 来确定歧义词汇的真实含义。利用 Embedding 层将消歧特征转化为特征矩阵,作为 RNN 的输入。利用 SemEval-2007: Task#5 的训练语料对 RNN 进行优化。使用优化后的 RNN 对 SemEval-2007: Task#5 的测试语料进行语义分类。两组实验的消歧准确率如表 1 所示。

表 1 测试语料的消歧准确率

Tab. 1 Disambiguation accuracy of test corpus

	实验 1: 词形 + 贝叶斯消歧模型 / %	实验 2: 词形、词性、语义类 + RNN / %
表面	50.00	61.11
儿女	50.00	90.00
气象	37.50	87.45
望	69.20	92.33
中医	37.50	75.00
补	40.00	75.44
成立	59.30	70.00
赶	27.80	61.11
日子	46.88	50.00
长城	14.30	47.64
吃	60.90	47.78
动	60.00	50.00
叫	56.40	37.50

为了更直观地度量两种分类方法的性能,给出了表 1 的折线图,如图 4 所示。

由图 4 可见,RNN 词义消歧方法的准确率要高于贝叶斯词义消歧方法。其原因是在实验 2 中,选取了词形、词性和语义类 3 种特征来共同确定歧义词汇的含义,能够覆盖更多的语言学现象。在实验 1 中,仅选取了词形作为消歧特征。在语义分类方面,RNN 的分类性能要明显优于 Bayes 分类器。由此,可以得到结论:基于 RNN 的词义消歧方法要好于基于贝叶斯的词义消歧方法。




图 4 两种分类方法的性能对比

Fig. 4 Performance comparison of two classification methods

5 结论

本文提出了一种循环神经网络的词义消歧方法。以歧义词汇左右相邻的四个词汇单元的词形、词性和语义类作为消歧特征,使用 RNN 来判别歧义词汇的真实含义。使用 SemEval-2007: Task#5 的训练语料和哈尔滨工业大学的语义标注语料来优化 RNN 的参数,以提高词义消歧的精度。使用优化后的 RNN 对 SemEval-2007: Task#5 的测试语料进行词义消歧。实验结果表明:RNN 词义消歧方法的准确率要优于贝叶斯词义消歧方法。

参考文献:

- [1] 鹿文鹏, 黄河燕. 基于依存适配度的知识自动获取词义消歧方法[J]. 软件学报, 2013, 24(10): 2300.
LU Wenpeng, HUANG Heyan. Word Sense Disambiguation Based on Dependency Fitness with Automatic Knowledge Acquisition[J]. Journal of Software, 2013, 24(10): 2300.
- [2] 鹿文鹏, 黄河燕, 吴昊. 基于领域知识的图模型词义消歧方法[J]. 自动化学报, 2014, 40(12): 2836.
LU Wenpeng, HUANG Heyan, WU Hao. Word Sense Disambiguation with Graph Model Based on Domain Knowledge[J]. Journal of Automation, 2014, 40(12): 2836.
- [3] 杨陟卓, 黄河燕. 基于语言模型的有监督词义消歧模型优化研究[J]. 中文信息学报, 2014, 28(1): 19.
YANG Zhizhuo, HUANG Heyan. Supervised WSD Model Optimization Based on Language Model[J]. Journal of Chinese Information Processing, 2014, 28(1): 19.
- [4] 王少楠, 宗成庆. 一种基于双通道 LDA 模型的汉语词义表示与归纳方法[J]. 计算机学报, 2016, 38(8): 1652.
WANG Shaonan, ZONG Chengqing. A Dual-LDA Method on Chinese Word Sense Representation and Induction[J]. Chinese Journal of Computers, 2016, 38(8): 1652.
- [5] 唐共波, 于东, 荀恩东. 基于知网义原词向量表示的无监督的词义消歧方法[J]. 中文信息学报, 2015, 29(6): 23.
TANG Gongbo, YU Dong, XUN Endong. An Unsupervised Word Sense Disambiguation Method Based on the Representation of Sememe in HowNet[J]. Journal of Chinese Information Processing, 2015, 29(6): 23.
- [6] 杨陟卓, 黄河燕. 基于异构关系网络图的词义消歧研究[J]. 计算机研究与发展, 2013, 50(2): 437.
YANG Zhizhuo, HUANG Heyan. WSD Method Based on Heterogeneous Relation Graph[J]. Journal of Computer Research and Development, 2013, 50(2): 437.
- [7] 张振景, 李新福, 田学东, 等. 基于 SVM 的离合词词义消歧[J]. 计算机科学, 2016, 43(2): 239.
ZHANG Zhenjing, LI Xinfu, TIAN Xuedong, et al. Liheci Word Sense Disambiguation Based on SVM[J]. Computer Science, 2016, 43(2): 239.
- [8] 范弘屹, 张仰森, 等. 一种基于 HowNet 的词语语义相似度计算方法[J]. 北京信息科技大学学报, 2014, 29(4): 42.
FAN Hongyi, ZHANG Yangsen, et al. Computing Method for Semantic Similarity of Words Based on HowNet[J]. Journal of Beijing Information Science and Technology University, 2014, 29(4): 42.
- [9] 张健立. 一种基于语义关系图的词义消歧算法[J]. 科技通报, 2015, 31(3): 228.
ZHANG Jianli. Word Sense Disambiguation Algorithm Based on Semantic Relation Graph[J]. Bulletin of Science and Technology, 2015, 31(3): 228.
- [10] ZHU Wensheng. Semi-supervised Word Sense Disambiguation Using Von Neumann Kernel[J]. International Journal of Innovative Computing Information & Control, 2017, 13(2): 695.
- [11] HUANG Zhehuang, CHEN Yidong. An Improving SRL Model With Word Sense Information Using An Improved Synergetic Neural Network Model[J]. Journal of Intelligent & Fuzzy Systems, 2016, 31(3): 1469.
- [12] ABUALHAIJA S, ZIMMERMANN K H. D-Bees: A Novel Method Inspired By Bee Colony Optimization For Solving Word Sense Disambiguation[J]. Swarm & Evolutionary Computation, 2016, 27(1): 188.
- [13] HUNG C, CHEN S J. Word Sense Disambiguation Based Sentiment Lexicons for Sentiment Classification[J]. Knowledge-Based Systems, 2016, 110(1): 224.
- [14] 史兆鹏, 邹徐熹, 向润昭, 等. 基于依存句法分析的多特征词义消歧[J]. 计算机工程, 2017, 43(9): 210.
SHI Zhaopeng, ZOU Xuxi, XIANG Zhaorun. Multi-feature Word Sense Disambiguation Based on Dependency Parsing Analysis[J]. Computer Engineering, 2017, 43(9): 210.
- [15] 高璐, 赵小兵. 一种实例库与义原关系相结合的概念消歧算法[J]. 首都师范大学学报(自然科学版), 2016, 37(3): 7.
GAO Lu, ZHAO Xiaobing. A Concept Disambiguation Algorithm Based on Case Library and Sememe Relation[J]. Journal of Capital Normal University (Natural Science Edition), 2016, 37(3): 7.
- [16] 钱涛, 姬东鸿, 戴文华. 一个基于超图的词义归纳模型[J]. 四川大学学报(工程科学版), 2016, 48(1): 152.
QIAN Tao, JI Donghong, DAI Wenhua. A Hypergraph Model for Word Sense Induction[J]. Journal of Sichuan University (Engineering Science Edition), 2016, 48(1): 152.
- [17] 任海英, 于立婷. 一种基于维基百科的多策略词义消歧方法[J]. 现代图书情报技术, 2015, 31(11): 18.
REN Haiying, YU Liting. A Multi Strategy Word Sense Disambiguation Method Based on Wikipedia[J]. Modern Library and Information Technology, 2015, 31(11): 18.
- [18] 刘翥, 钟云, 刘瑶. 基于语义一致性的集成实体链接算法[J]. 计算机研究与发展, 2016, 53(8): 1696.
LIU Qiao, ZHONG Yun, LIU Yao. Consistent Collective Entity Linking Algorithm[J]. Journal of Computer Research and Development, 2016, 53(8): 1696.
- [19] 许坤, 冯岩松, 赵东岩, 等. 面向知识库的中文自然语言问句的语义理解[J]. 北京大学学报(自然科学版), 2014, 50(1): 85.
XU Kun, FENG Yansong, ZHAO Dongyan, et al. Automatic Understanding of Natural Language Questions for Querying Chinese Knowledge Bases[J]. Acta Scientiarum Naturalium Universitatis Pekinensis (Natural Science Edition), 2014, 50(1): 85.
- [20] 杨安, 李素建, 李芸. 基于领域知识和词向量的词义消歧方法[J]. 北京大学学报(自然科学版), 2017, 53(2): 204.
YANG An, LI Suyun, LI Yun. Word Sense Disambiguation Based on Domain Knowledge and Word Vector Model[J]. Acta Scientiarum Naturalium Universitatis Pekinensis (Natural Science Edition), 2017, 53(2): 204.
- [21] 刘明珠, 郑云非, 樊金斐, 等. 基于深度学习法的视频文本区域定位与识别[J]. 哈尔滨理工大学学报, 2016, 21(6): 61.
LIU Mingzhu, ZHENG Yunfei, FAN Jinfei, et al. Area Location and Recognition of Video Text Based on Depth Learning Method[J]. Journal of Harbin University of Science and Technology, 2016, 21(6): 61.

(编辑: 温泽宇)