

基于整数线性规划重构抽象语义图结构的语义摘要算法

陈鸿昶 明拓思宇* 刘树新 高超

(国家数字交换系统工程技术研究中心 郑州 450002)

摘要: 针对利用抽象语义(AMR)图来预测摘要子图存在的语义结构不完整问题, 该文提出一种基于整数线性规划(ILP)重构AMR图结构的语义摘要算法。首先将数据预处理生成一个AMR总图; 然后基于统计特征从AMR总图中抽取摘要子图重要节点信息; 最后利用ILP的方法来对摘要子图中节点关系进行重构, 利用完整的摘要子图恢复生成语义摘要。实验结果表明, 相比其他语义摘要方法, 所提方法的ROUGE值和Smatch值都有显著提高, 最多分别提高了9%和14%, 该方法有利于提高语义摘要的质量。

关键词: 抽象语义图; 语义摘要; 摘要子图; 语义结构; 整数线性规划

中图分类号: TP391.1

文献标识码: A

文章编号: 1009-5896(2019)07-1674-08

DOI: [10.11999/JEIT180720](https://doi.org/10.11999/JEIT180720)

Semantic Summarization of Reconstructed Abstract Meaning Representation Graph Structure Based on Integer Linear Programming

CHEN Hongchang MING Tuosiyu LIU Shuxin GAO Chao

(National Digital Switching System Engineering Technological Research Center, Zhengzhou 450002, China)

Abstract: In order to solve the incomplete semantic structure problem that occurs in the process of using the Abstract Meaning Representation (AMR) graph to predict the summary subgraph, a semantic summarization algorithm is proposed based on Integer Linear Programming (ILP) reconstructed AMR graph structure. Firstly, the text data are preprocessed to generate an AMR total graph. Then the important node information of the summary subgraph is extracted from the AMR total graph based on the statistical features. Finally, the ILP method is applied to reconstructing the node relationships in the summary subgraph, which is further utilized to generate a semantic summarization. The experimental results show that compared with other semantic summarization methods, the ROUGE index and Smatch index of the proposed algorithm are significantly improved, up to 9% and 14% respectively. This method improves significantly the quality of semantic summarization.

Key words: Abstract Meaning Representation (AMR) graph; Semantic summarization; Summary subgraph; Semantic structure; Integer Linear Programming (ILP)

1 引言

语义摘要是旨在通过挖掘语句之间的语义关系来生成与原文档语义表达上一致的摘要。现有的语义摘要方法主要包括利用外部语义资源^[1]、语义聚类^[2]、TextRank算法^[3]、潜在语义分析(Latent Semantic Analysis, LSA)^[4]、PAS语义图^[5]等方

法。虽然以上这些方法在一定程度上利用了语句间的语义关系来生成文本摘要, 但是它们都只利用了文本的浅层语义关系, 并未充分挖掘和利用文档深度语义信息。

为了进一步挖掘利用深度语义, Banarescu等人^[6]提出了一种抽象语义(Abstract Meaning Representation, AMR)图的方法来全面描述句子的完整语义结构。本文借助AMR图的方法进一步利用深层语义信息来完成摘要的生成。与传统的抽取式文本摘要相比, 基于AMR图的语义摘要则不会忽略具有重要语义的低频词, 这有利于更好地理解摘要表达的完整语义; 与上述传统的语义摘要相比, 基于AMR图的语义摘要能够更好选取具有重要语义的实词, 忽略对理解无关紧要的虚词语义, 这有

收稿日期: 2018-07-18; 改回日期: 2018-10-26; 网络出版: 2018-11-19

*通信作者: 明拓思宇 1139446336@qq.com

基金项目: 国家自然科学基金(61521003), 国家自然科学基金青年科学基金(61601513)

Foundation Items: The National Natural Science Foundation of China (61521003), The National Natural Science Foundation of China Youth Science Fund (61601513)

利于从固定压缩比的文本摘要中获取更多的关键有用信息。因此总体来说，基于AMR图的语义摘要的方法在一定程度上能够改善语义文本摘要的质量。

Liu等人^[7]首次将AMR图用于文本摘要工作，依据文本句子生成相应的AMR图表示，然后从AMR图中提取重要部分恢复生成摘要。但是Liu方法中是基于特征对重要语义的实词节点进行抽取，选取到的实词节点相对比较零散，节点之间可能原本不存在直接的语义关系或者存在多个并列的语义，因此导致最后生成的AMR摘要子图中实词节点之间的关系可能存在有所缺失或者表达不明确的问题。

为了使文本摘要的语义表达更加连贯和准确，因此亟需一种方法对重要语义节点之间的边关系进行重构以解决节点间语义缺失问题。因此，本文提出一种基于整数线性规划(ILP)重构AMR图结构的语义摘要算法，对摘要AMR图的重要语义节点之间的边关系进行重构，从而进一步提高文本摘要语义表达的可读性和一致性。

2 基于ILP重构AMR图结构的语义摘要算法

针对摘要子图节点间语义结构不完整的问题，本文提出了基于ILP重构AMR图结构的语义摘要算法框架，其总体流程如图1所示，框架首先将文本数据进行预处理并生成相应的AMR总图，其次基于语义统计特征对AMR总图进行抽取得到重要语义节点，最后利用ILP的方法对重要语义节点之间的语义边属性关系进行重构，生成语义完整的文本摘要。

2.1 数据预处理生成AMR总图

对文本数据进行预处理提高文档数据质量。首先对文档集中的句子进行分句处理，然后对句子进行指代消解、词性过滤(过滤剩下名词、动词、形容词3种词性的词)、去除停用词等预处理操作后，利用JAMR自动解析器^[8,9]对每句话解析生成相应的AMR图。




图1 算法框架图

如图2所示，在语义图中，每个节点表示一个独立的实词概念，边是带有语义标签的有向弧。在AMR图中，无论一个实词在句子中出现了多少次，它在AMR图中都被规范化为一个独立的概念节点，将这个规范化的原则扩展到多个句子中，理想情况下可以生成一个没有冗余节点的AMR总图。

考虑到每个句子都会生成一个相应的AMR图，为了确保每个AMR图都被连接，添加一个“root”节点来连接各个AMR图的概念根节点(例如：图3中的“see-01”和“chase-01”节点)，使多个AMR图连通成一个AMR总图。由于同一实词概念在AMR图中只以同一节点的形式存在，因此

需要对连通AMR总图中的相同概念节点进行合并，生成没有冗余节点的连通AMR总图。首先对相同概念节点进行合并，将图3示例中的相同节点(“dog”)合并为一个；接着基于WordNet语义字典来计算语义相似的概念节点，例如图3所示的“run-02”和“chase-01”两个概念节点就具有较高的语义相似度，因此将其融合为一个节点(“chase-01”)，并保留节点之间对应的边属性关系，从而就得到了去除冗余信息的连通AMR总图。

2.2 基于统计特征抽取重要语义节点

考虑到文档数据对应生成的AMR图节点数量庞大，会给整数线性规划过程带来巨大的计算量，

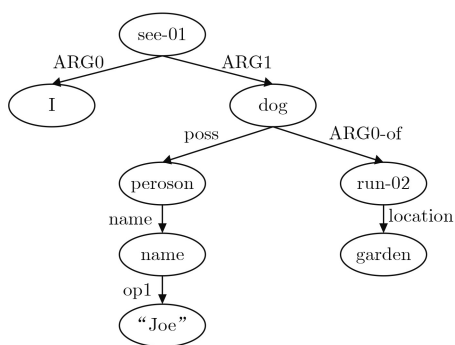


图2 英文句“I saw Joe’s dog, which was running in the garden”的AMR图表示

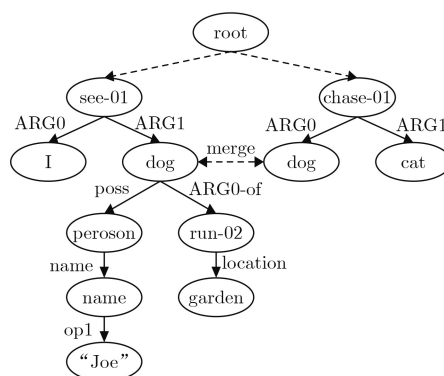


图3 AMR图合并生成AMR总图示意图

使算法的可实现性降低。因此先抽取重要语义节点来降低计算复杂度,进而利用重要语义节点重构AMR摘要子图。

这里,利用抽取式摘要方法来抽取重要语义节点。依据AMR图结构综合利用统计特征来从AMR总图中抽取出摘要子图重要语义节点集合。考虑到文本的基本特征和语义结构中语义相关特征对摘要的影响,在此基于如下几个统计特征来抽取重要节点:

(1)TF-IDF特征:

$$w_t = \text{tfidf}_{i,j} = \text{tf}_{i,j} \times \text{idf}_i \quad (1)$$

(2)句子位置特征:

$$w_l(s_i) = \begin{cases} 1.0, & s_i \text{为首句} \\ 0.5, & s_i \text{为尾句} \\ 0, & s_i \text{为其他句} \end{cases} \quad (2)$$

(3)词位置特征:

$$w_p = \frac{1}{p_1} + \frac{1}{p_2} + \dots + \frac{1}{p_n} \quad (3)$$

其中, $p_i, i = 1, 2, \dots, n$ 是给定单词在句子中出现位置的序号, n 是单词出现的次数。

(4)实体概念特征:

$$w_c = \begin{cases} 0, & \text{概念不是命名实体} \\ 1, & \text{概念是命名实体} \end{cases} \quad (4)$$

在上述特征的基础上,考虑到AMR图的特殊语义结构,本文提出一种AMR图节点语义结构深度的特征来刻画节点在AMR语义图结构中的重要性。由于在同一个语义树图结构中,越靠近根节点的节点具有语义逻辑基点的作用,往往具有更高的语义重要性程度,为了保证句子语义和结构的完整性,这些节点往往需要保留下来构成重要图部分。此前没有可以用来刻画语义图结构中节点语义重要性的特征,因此,这里提出一个新的特征来刻画节点的语义重要性。

(5)AMR图节点语义结构深度特征:

定义 由于AMR是树形图结构,定义AMR图的深度为AMR树形图节点的最大层数(也即树的深度),节点的语义结构深度是指在语义树型图结构中节点所处的层数。节点的语义结构深度越浅,其语义重要性程度越高。因此,节点的语义结构深度特征的相关权重为

$$w_d = 1 - \frac{d_i - 1}{d} \quad (5)$$

其中, d_i 为给定单词在AMR图中的语义结构深度, d 为给定单词所在AMR图的深度。

利用稀疏自编码器将以上统计特征综合考虑^[10],对原本不具有权值的抽象语义图结构中的相应节点赋予权重,根据抽取比例来抽取出特定数量的重要语义节点。

2.3 基于ILP的节点关系重构

一个完整的语义摘要既要包含重要信息,又要保证信息之间语义关系的完整。利用重要语义节点生成一个具有完整语义关系的摘要子图的过程相当于一个结构化预测问题。这里,利用统计模型中的特征和约束条件来重构节点关系生成语义完整的摘要子图。

最终文本摘要AMR图节点的集合包含于通过2.2节抽取的特定数量重要语义节点的集合中,但是不同的是,这些节点之间并未建立边的连接,这里需要生成的是一个具有完整节点和边关系的AMR语义摘要子图,因此需要对这些重要语义节点之间的边关系进行重构,于是利用ILP的方法来实现节点关系重构。

通过ILP的算法来重构AMR图节点关系的算法主要分为两个步骤,一是确定目标函数,二是确定约束条件,然后在满足约束条件的情况下寻求目标函数的最大化。主要流程如下:首先,根据边的语义相关特征确定目标函数;目的是通过最大化摘要子图的语义边关系得分来实现第2.2节中重要节点之间边关系的重构;然后确定约束条件。为了保证生成有效的摘要AMR子图,需要确保节点之间都有效地连通起来,同时还需要利用约束条件对生成摘要子图的大小进一步约束限制。

2.3.1 目标函数及其计算方法

首先,确定目标函数。将AMR图用符号化的形式表示。令 $G = (V; E)$ 表示AMR总图,其中每个节点 $v \in V$ 表示一个独立的概念,每个有向边 $e \in E$ 连接两个概念, G 是一个具有语义关系标签的有向边连接图。通过2.2节抽取生成的重要语义节点集合为 V' ,节点数量为 M ,待完善语义关系的摘要子图为 G' 。由于利用统计特征来抽取重要语义节点的期间不对语义边标签进行预测,因此摘要子图 G' 的边集合 E' 为空,下一步对节点边关系进行预测重构。在这里,定义摘要子图 $G' = (V'; E')$ 的语义边关系得分的目标函数为

$$\text{score}(E', \theta) = \sum_{e' \in E'} \theta^T f(e') \quad (6)$$

其中, $f(e')$ 是边 e' 的特征表示, θ 是线性模型中经验估计系数的向量。利用ILP的方法试图最大化式(6)目标函数得分来重构重要语义节点之间的边关系。选定语义相关的边特征如下:

(1)节点重要性特征：根据2.2节，令节点*i*重要性为 $\text{imp}(s_i)$ ，考虑边两端的节点重要性特征 w_n 为

$$w_n = \frac{\text{imp}(s_i) + \text{imp}(s_j)}{2\text{imp}(s_{\max})} \quad (7)$$

其中， $\text{imp}(s_{\max})$ 是 $\text{imp}(s_i), i = 1, 2, \dots, M$ 中的最大值。

(2)标签特征：根据节点间原有的语义标签关系定义 w_l

$$w_l = \begin{cases} 0, & \text{节点之间不存在语义标签} \\ 1, & \text{节点之间存在语义标签} \end{cases} \quad (8)$$

(3)位置特征：根据两端节点在AMR图中的语义结构位置，通过索引标号之和定义 w_p

$$w_p = \frac{i + j}{2N} \quad (9)$$

(4)频率特征：对于有多个语义标签引入的节点，定义 w_f

$$w_f = \begin{cases} 1.0, & \text{出现频率第1的语义标签} \\ 0.5, & \text{出现频率第2的语义标签} \\ 0, & \text{其他} \end{cases} \quad (10)$$

参数 θ 利用Collins^[11]提出的结构感知器来学习得到，对应地，给定输入为重要语义节点集合，输出为标准摘要的AMR图集合。

2.3.2 寻找约束条件

最后，确定约束条件。将摘要子图节点语义边关系的重构看成带约束的ILP优化过程，其约束条件是确保恢复输出连通的AMR摘要子图。用概念节点*i, j*对AMR总图重新进行索引，其中，“root”节点的索引为0，*N*为图*G*中节点数；摘要子图*G'*中使用和AMR总图*G*相同的节点索引标号。 v'_i 和 $e'_{i,j}$ 为二值变量，如果摘要子图*G'*包含AMR总图中的节点*i*，则 v'_i 为1，否则为0。只有两个节点都属于节点集合*V'*，它们之间才可能存在边关系，即如果满足条件 $i, j \in V'$ ，则 $e'_{i,j}$ 为0或1，否则 $e'_{i,j}$ 均为0。

ILP最大化的目标函数式(6)用符号重写为

$$\text{score} = \sum_{(i,j) \in G'} \theta^T e'_{i,j} \mathbf{f}(i,j) \quad (11)$$

式(11)目标函数是关于 $e'_{i,j}$ 的线性函数，特征和系数组合成边的得分，其中， $\theta^T \mathbf{f}(i,j)$ 是边的得分，在ILP优化重构节点语义关系过程中它们都作为常量来处理。

对于摘要子图中的*i, j*，如果它们在图*G*中存在唯一的语义边关系，那么摘要子图*G'*中仍会保留这份语义关系，即 $e'_{i,j}=1$ 。

需要添加一定的约束条件来确保选定的重要节点集合之间能够生成一个有效的AMR图。为了更好地用约束条件来表示图的连通性，在此引入流量的概念，流量通过边来传输，经过节点后消耗。用一组单连通变量 $f_{i,j}$ 来表示从节点*i*到节点*j*的流量，其中每个变量都为非负整数值。从根节点流向*M*个节点的流量等于图中每个节点所消耗的流量之和，因此有

$$\sum_i f_{0,i} - \sum_i v'_i = 0 \quad (12)$$

对于节点来说，它的流入流量和流出流量之间是相等的，每经过图所包含的一个节点就消耗一个流量单元。利用流量守恒的定律建立如式(13)所示约束条件：

$$\sum_i f_{i,j} - \sum_k f_{j,k} - v'_j = 0, \quad \forall j \leq N \quad (13)$$

如果两个节点之间存在边连接，那么它们之间可以通过边来传输流量，因此

$$M \cdot e'_{i,j} - f_{i,j} \geq 0, \quad \forall i, j \leq N \quad (14)$$

最后生成的语义摘要子图是单根树形结构图，因此对于图中任意节点，每个节点最多只有一个传入的边

$$\sum_i e'_{i,j} \leq 1, \quad \forall j \leq N \quad (15)$$

抽取式文本摘要的大小取决于压缩率，压缩率大小也一定程度上影响着文本摘要的质量。压缩率越大，摘要中包含的信息也越多，所以评价文本摘要质量应该控制在相同压缩率的条件下进行，这里提出一个约束条件来控制摘要图的大小(类似于控制相同压缩率)，将最后生成的语义摘要子图中边的数量固定为*L*

$$L = \sum_i \sum_j e'_{i,j} \quad (16)$$

这里，语义摘要子图边的数量*L*被用来代替压缩率来控制生成摘要大小。

在满足约束条件的情况下，寻求目标函数的最大化来对AMR图中的相应边关系进行重构补全。目标函数最大化时得到的AMR图就是重构生成的具有完整语义的AMR摘要子图。

3 实验

3.1 实验数据集和评价指标

为了验证重构AMR图语义结构对摘要质量提高的影响效果，本文使用Hermann等人^[12]提出的CNN和DailyMail两个大规模数据集进行实验来对

文本摘要任务进行测评。该数据集是大量附有要点总结的CNN和DailyMail新闻文章，其中大约包含有 1.2×10^5 个训练数据， 7×10^4 个验证数据和 6×10^4 个测试数据。文章中平均有30个句子和800个标志，其中每个问题包含12~14个标志，同时摘要中的平均句子数为3~4句。

$$\text{ROUGE-N} = \frac{\sum_{S \in \{\text{Ref Summaries}\}} \sum_{n\text{-gram} \in S} \text{Count}_{\text{match}}(n\text{-gram})}{\sum_{S \in \{\text{Ref Summaries}\}} \sum_{n\text{-gram} \in S} \text{Count}(n\text{-gram})} \quad (17)$$

其中， n 表示 n -gram的长度，{Reference Summaries}表示参考摘要，即事先获得的标准摘要， $\text{Count}_{\text{match}}(n\text{-gram})$ 表示评估摘要和参考摘要中同时出现的 n -gram个数。

此外，为了从语义层面更好地衡量摘要语义的完整性，这里除了采用基于字对齐的ROUGE指标来评价摘要质量以外，同时还采用基于语义特征结构之间重叠程度的Smatch评价指标来对摘要质量进行评价。除了专门用于摘要评价的指标以外，还有基本的准确率 P 、召回率 R 和 $F1$ 分数用于实验分析。其中， $F1\text{-score} = \frac{2PR}{P+R}$ 。

3.2 实验结果与分析

3.2.1 摘要子图重构效果验证

本文方法是以图的结构形式来描述摘要内容及语义结构，因此将生成摘要子图与标准摘要的AMR图结构进行对比，观察摘要子图预测正确的节点和边的比例，实验效果展示图和实验结果如图4和表1。

从表1给出的实验结果可以看出，本文方法生成的语义摘要具有良好的摘要质量。节点预测的正确率表示生成摘要对于文本重要内容提炼的多少，正确率越高表示生成摘要的概括性越强；边预测的正确率表示生成摘要在语义结构上的完整性，正确率越高表示生成摘要的语义流畅性和可读性越高。总的来说，二者均具有较高的预测正确率，本文方法生成摘要基本覆盖了文本大部分重要信息的同时

实验使用ROUGE指标^[13]和Smatch指标^[14]来综合衡量生成的语义摘要的质量好坏。ROUGE用于衡量机器生成摘要和人工合成摘要之间的一致性。它基于机器摘要和人工摘要之间的 n 元词(n -gram)共现信息来评价摘要质量，是一种面向 n 元词召回率的评价方法。ROUGE-N的计算公式为

也具有较高的语义完整性。通过对比实验效果展示图4，可以看出文本表达的中心语义内容基本一致，生成摘要子图的节点和边的预测正确率较高，摘要具有较高质量水平。

3.2.2 语义摘要算法性能对比分析

由于本文算法是基于语义层面的语义摘要方法，因此实验选取利用外部语义资源、语义聚类、Text-Rank算法、潜在语义分析等语义摘要的方法作为比较算法。依据ROUGE值和Smatch值来对摘要语义内容和语义结构进行评价，实验结果如表2。

从表2显示的实验结果可以看出，本文提出的基于ILP重构AMR图结构的语义摘要算法相比其他语义摘要比较算法，在ROUGE指标和Smatch指标上均取得了最优的实验效果。文中方法在ROUGE-1、ROUGE-2指标上有较大提升，高的ROUGE-1、ROUGE-2值反映出摘要较好地抽取了重要语义内容；Smatch值相比其他算法有显著地提升，反映出摘要的语义结构得到了较好的优化重构。

借助外部语义资源来辅助确定文档重要词汇、获取词间语义关系和基于语义聚类的方法都是依据简单的词间语义关系，因此二者的ROUGE指标和Smatch指标均偏小，且实验效果较为接近。潜在语义分析的方法相比前两者，不仅考虑了词间语义关系，还融合主题模型挖掘了词语背后的信息，因此实验效果较前两者有一定程度上的提高。Text-

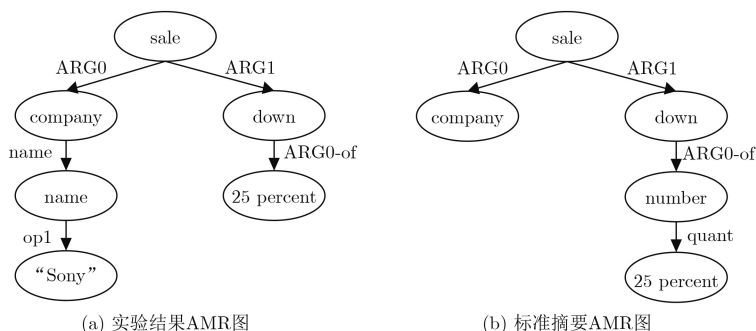


图4 实验结果AMR图与标准摘要AMR图的对比

表1 摘要子图节点和边预测正确率(%)

	<i>P</i>	<i>R</i>	<i>F1</i>
节点	71.4	82.5	76.5
边	45.6	60.1	51.9

表2 不同语义摘要算法的性能对比

算法	ROUGE-1	ROUGE-2	ROUGE-W	Smatch
外部语义资源	20.4	5.6	14.3	17.8
语义聚类	21.2	6.0	15.2	19.1
潜在语义分析	22.8	6.8	14.9	20.5
TextRank算法	25.7	8.1	16.8	24.6
PAS语义图	26.5	9.6	18.6	28.9
本文方法	29.3	10.4	19.6	32.1

Rank算法是依据滑动窗口大小的共现词的语义关系建立连边，较好地保存多元词的共现信息，因此ROUGE值较之前方法有显著地提高；而且多元词的结构保留相对完整，句子语义结构较好地保存了下来，因此Smatch值相比之前有大幅度提高。PAS语义图的方法相比其他比较算法进一步地利用了句子级别的语义关系，更好地挖掘了深层语义信息，因此相比之前方法无论ROUGE值还是Smatch值都有显著的效果提升。本文基于ILP重构AMR图结构的语义摘要算法充分地挖掘和利用了句子篇章级语义信息，同时在构建AMR图的过程中较好地忽略了较虚的语义词，有利于筛选出具有重要语义的内容，因此相比PAS语义图算法，ROUGE-1, ROUGE-2和ROUGE-W值均有一定地提高，分别提高了2.8%, 0.8%和1.0%。依据ILP的方法对抽取后的重要语义词之间的语义关系进行连接重构，使得语义结构得以完善，所以在Smatch值上相较于PAS语义图的方法提升明显，提升了3.2%。总体来说，利用ILP来重构AMR图结构的方法一定程度上优化完善了摘要子图的语义结构关系，显著提高了摘要的连贯性和语义完整性，使得生成摘要的可读性大大提高。

3.2.3 ILP方法对摘要质量的影响

为了了解利用ILP方法重构重要语义词之间的语义关系是否有助于完善摘要语义结构，所以将使用ILP和未使用ILP两者的结果进行对比，对比结果如表3。

从表3的实验结果来看，由于二者抽取重要语义节点采用的是相同的方法，因此在ROUGE-1值上基本没有差别。使用ILP的方法相比未使用ILP的方法，实际上是前者在后者抽取出的重要语

表3 使用ILP和未使用ILP摘要质量对比

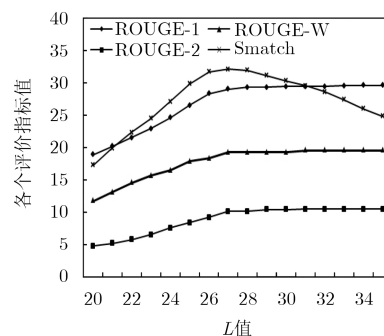
	ROUGE-1	ROUGE-2	ROUGE-W	Smatch
未使用ILP	29.1	9.8	18.7	29.7
使用ILP	29.3	10.4	19.6	32.1
结果提升	0.2	0.6	0.9	2.4

义节点基础上利用ILP重构语义关系，大部分重要语义内容都保留了下来，只对重要内容之间的语义关系进行了补充完善，因此ROUGE-2和ROUGE-W值都有小幅度地提高，提升不到1.0%。利用ILP来重构优化AMR图的语义结构在一定程度上使句子语义更加通顺，具有更高的可读性，所以相比未使用ILP的方法，本文方法在衡量语义结构的Smatch指标上有明显的提高，提升了2.4%。

3.2.4 摘要子图边数*L*对摘要质量的影响

抽取式文本摘要的大小取决于压缩率，压缩率大小一定程度上影响着生成摘要的质量。本文借助ILP方法对摘要子图添加一个约束条件，即将摘要子图边的数量固定为*L*来代替压缩率控制文本摘要的大小，因此进一步研究这个约束条件对摘要质量的影响。实验结果如图5。

从图5实验结果显示，在区间 $L \in [20, 30]$ ，随着*L*值逐渐增大，摘要大小也相应增大。摘要内容增多的结果是能匹配上的*n*元词和3元组个数增多，因此导致Smatch和各个ROUGE值也逐渐增大。之后随着*L*值继续地增加，尽管摘要内容仍然在增多，但是有用信息并不是无限制地增长，增加的只是冗余信息，能匹配上的*n*元词数量基本保持不变，标准摘要的大小也是不变的，因此ROUGE值逐渐趋于稳定值。相对而言，Smatch值的得分是*F1*分数。虽然随着摘要内容的增多，能匹配上的3元组个数趋于稳定，准确率*P*不变，但是随着摘要长度的增加，召回率*R*降低了，因此Smatch值的得分*F1*分数随着*L*值的继续增大而逐渐下降。ROUGE-1, ROUGE-2, ROUGE-W等3个值变化趋势是随着*L*值的逐渐增大，其值是先增大随后趋于

图5 *L*值对摘要质量各指标的影响

一个稳定值, Smatch值的变化趋势是随着 L 值逐渐增大, 其值是先增大到一个最大值随后逐渐减小。通过观察上述实验结果图得出, 摘要子图边数 L 为26~28时, 文本摘要评价指标ROUGE-1, ROUGE-2, ROUGE-W和Smatch值儿者综合来说具有最优的实验结果, 得到的文本摘要具有最佳的质量效果。

3.2.5 与深度学习算法的比较

深度学习具备有强大的表征能力, 能够提取比人为提取特征具有更强泛化能力的特征, 因此利用深度学习方法可以很好地获取特征, 挖掘深层语义信息。深度学习在文本摘要中^[15,16]也取得很好的应用。

为了更好验证和对比, 将本文方法与深度学习文本摘要算法基于相同的数据集进行实验, 结果如表4。

表4 与深度学习算法的性能对比

方法	ROUGE-1	ROUGE-2	ROUGE-W	Smatch
本文方法	29.3	10.4	19.6	32.1
深度学习	33.4	13.6	24.8	26.7

从表4的实验结果来看, 本文方法在各个ROUGE值与最优的深度学习文本摘要方法还是存在一定的差距, 这是由于深度神经网络具有复杂的网络结构, 能够拟合任意复杂函数, 其强大的表征学习能力, 可以提取到比人为提取特征更强的特征, 因此在ROUGE值的实验结果上一定程度领先于本文的方法, 各个ROUGE值上都高于本文方法3%~5%。但是深度学习不便于解释其内部特征提取的方法, 因而不能进一步完善和改进实验结果。同时, 为了更好地提高ROUGE值指标, 现有深度学习方法忽略了摘要句子语法结构方面的综合考虑, 导致与句子语义特征相关的Smatch值明显低于本文方法, 本文方法要高出5.4%, 这说明本文摘要方法具有更好的可读性。在此启发下想到, 如果能将AMR图的方法结合深度学习来解决文本摘要问题, 应该能更好地解决篇章级语义信息利用和强特征提取的问题。在提高文本摘要语义内容的正确性的同时, 提高其语义结构的完整性, 进而更好地提升文本摘要的质量效果。

4 结束语

本文在基于统计特征从AMR图中抽取重要图部分生成摘要的基础上, 提出了一种基于ILP重构AMR图结构的语义摘要算法来解决重要语义词之间的语义关系缺失或者表达不明确的问题。本文算

法首先通过抽取AMR图重要语义节点来降低计算复杂度; 接着依据ILP方法最大化目标函数得分来重构优化节点语义关系, 并通过约束条件控制生成适合大小的AMR摘要子图, 最后依据完整的摘要子图恢复生成语义摘要。实验结果表明, 本文提出的方法与其他语义摘要算法相比在ROUGE值和Smatch值上具有明显提高, 文本摘要的内容一致性和语义连贯性一定程度上都有提高。考虑到计算复杂度的影响, 本文方法比较适用于新闻文本摘要等短句摘要的场景。在接下来工作中将考虑如何将AMR图与深度学习结合开展进一步的研究。

参考文献

- [1] LYNN H M, CHOI C, and KIM P. An improved method of automatic text summarization for web contents using lexical chain with semantic-related terms[J]. *Soft Computing*, 2018, 22(12): 4013-4023. doi: [10.1007/s00500-017-2612-9](https://doi.org/10.1007/s00500-017-2612-9).
- [2] SHETTY K and KALLIMANI J S. Automatic extractive text summarization using K-means clustering[C]. International Conference on Electrical, Electronics, Communication, Computer, and Optimization Techniques (ICEECCOT), Mysuru, India, 2017: 1-9. doi: [10.1109/ICEECCOT.2017.8284627](https://doi.org/10.1109/ICEECCOT.2017.8284627).
- [3] YU Shanshan, SU Jindian, LI Pengfei, et al. Towards high performance text mining: A TextRank-based method for automatic text summarization[J]. *International Journal of Grid and High Performance Computing (IJGHPC)*, 2016, 8(2): 58-75. doi: [10.4018/IJGHPC.2016040104](https://doi.org/10.4018/IJGHPC.2016040104).
- [4] NGUYEN-HOANG T A, NGUYEN K, and TRAN Q V. TSGVi: A graph-based summarization system for Vietnamese documents[J]. *Journal of Ambient Intelligence and Humanized Computing*, 2012, 3(4): 305-313. doi: [10.1007/s12652-012-0143-x](https://doi.org/10.1007/s12652-012-0143-x).
- [5] KHAN A, SALIM N, FARMAN H, et al. Abstractive text summarization based on improved semantic graph approach[J]. *International Journal of Parallel Programming*, 2018: 1-25. doi: [10.1007/s10766-018-0560-3](https://doi.org/10.1007/s10766-018-0560-3).
- [6] BANARESU L, BONIAL C, CAI S, et al. Abstract meaning representation for sembanking[C]. Proceedings of the 7th Linguistic Annotation Workshop and Interoperability with Discourse, Sofia, Bulgaria, 2013: 178-186.
- [7] LIU Fei, FLANIGAN J, THOMSON S, et al. Toward abstractive summarization using semantic representations[C]. Proceedings of the 2015 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Denver, USA, 2015: 1077-1086. doi: [10.3115/v1/n15-1114](https://doi.org/10.3115/v1/n15-1114).
- [8] SONG Linfeng, PENG Xiaochang, ZHANG Yue, et al. AMR-to-text generation with synchronous node replacement grammar[C]. Proceedings of the 55th Annual Meeting of the

- Association for Computational Linguistics, Vancouver, Canada, 2017: 7–13. doi: [10.18653/v1/P17-2002](https://doi.org/10.18653/v1/P17-2002).
- [9] KONSTAS I, IYER S, YATSKAR M, *et al.* Neural AMR: Sequence-to-sequence models for parsing and generation[C]. Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics, Vancouver, Canada, 2017: 146–157. doi: [10.18653/v1/P17-1014](https://doi.org/10.18653/v1/P17-1014).
- [10] 明拓思宇, 陈鸿昶, 黄瑞阳, 等. 一种基于加权AMR图的语义子图预测摘要算法[J]. 计算机工程, 2018, 44(10): 292–297. doi: [10.19678/j.issn.1000-3428.0050770](https://doi.org/10.19678/j.issn.1000-3428.0050770).
MING Tuosiyu, CHEN Hongchang, HUANG Ruiyang, *et al.* A semantic subgraph predictive summary algorithm based on improved AMR graph[J]. *Computer Engineering*, 2018, 44(10): 292–297. doi: [10.19678/j.issn.1000-3428.0050770](https://doi.org/10.19678/j.issn.1000-3428.0050770).
- [11] COLLINS M. Discriminative training methods for hidden markov models: Theory and experiments with perceptron algorithms[C]. Proceedings of the ACL-02 conference on Empirical Methods in Natural Language Processing, Philadelphia, USA, 2002, 10: 1–8. doi: [10.3115/1118693.1118694](https://doi.org/10.3115/1118693.1118694).
- [12] HERMANN K M, KOČISKÝ T, GREFFENSTETTE E, *et al.* Teaching machines to read and comprehend[C]. Proceeding NIPS'15 Proceedings of the 28th International Conference on Neural Information Processing Systems, Montreal, Canada, 2015, 1: 1693–1701.
- [13] LIN Chinyew. ROUGE: A package for automatic evaluation of summaries[C]. Text Summarization Branches Out: Proceedings of the ACL-04 Workshop, Barcelona, Spain, 2004, 10: 74–81.
- [14] CAI Shu and KNIGHT K. Smatch: An evaluation metric for semantic feature structures[C]. Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics, Sofia, Bulgaria, 2013, 2: 748–752.
- [15] SEE A, LIU P J, and MANNING C D. Get to the point: Summarization with pointer-generator networks[C]. Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics, Vancouver, Canada, 2017, 1: 1073–1083. doi: [10.18653/v1/P17-1099](https://doi.org/10.18653/v1/P17-1099).
- [16] TAN Jiwei, WAN Xiaojun, and XIAO Jianguo. Abstractive document summarization with a graph-based attentional neural model[C]. Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics, Vancouver, Canada, 2017, 1: 1171–1181. doi: [10.18653/v1/P17-1108](https://doi.org/10.18653/v1/P17-1108).
- 陈鸿昶: 男, 1964年生, 教授, 博士生导师, 研究方向为通信与信息工程、网络大数据.
- 明拓思宇: 男, 1994年生, 硕士生, 研究方向为网络大数据、文本摘要.
- 刘树新: 男, 1987年生, 助理研究员, 研究方向为网络大数据、复杂网络.
- 高超: 男, 1982年生, 助理研究员, 研究方向为网络大数据、计算机视觉.