



计算机科学

COMPUTER SCIENCE

基于关键词异构图的生成式摘要研究

毛兴静, 魏勇, 杨昱睿, 琚生根

引用本文

毛兴静, 魏勇, 杨昱睿, 琚生根. [基于关键词异构图的生成式摘要研究](#)[J]. 计算机科学, 2024, 51(7): 278-286.

MAO Xingjing, WEI Yong, YANG Yurui, JU Shenggen. [KHGAS:Keywords Guided Heterogeneous Graph for Abstractive Summarization](#) [J]. Computer Science, 2024, 51(7): 278-286.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[融合多图卷积与层级池化的文本分类模型](#)

Text Classification Method Based on Multi Graph Convolution and Hierarchical Pooling

计算机科学, 2024, 51(7): 303-309. <https://doi.org/10.11896/jsjcx.230400164>

[一种基于异构图神经网络和文本语义增强的实体关系抽取方法](#)

Method for Entity Relation Extraction Based on Heterogeneous Graph Neural Networks and

TextSemantic Enhancement

计算机科学, 2024, 51(6A): 230700071-5. <https://doi.org/10.11896/jsjcx.230700071>

[融合帖文属性的性别歧视言论检测模型](#)

Gender Discrimination Speech Detection Model Fusing Post Attributes

计算机科学, 2024, 51(6): 338-345. <https://doi.org/10.11896/jsjcx.230800198>

[基于知识辅助的结构化医疗报告生成](#)

Generation of Structured Medical Reports Based on Knowledge Assistance

计算机科学, 2024, 51(6): 317-324. <https://doi.org/10.11896/jsjcx.230900076>

[基于句信息增强词信息的方面级情感分类](#)

Aspect-based Sentiment Classification for Word Information Enhancement Based on Sentence

Information

计算机科学, 2024, 51(6): 299-308. <https://doi.org/10.11896/jsjcx.230600059>

基于关键词异构图的生成式摘要研究

毛兴静¹ 魏勇² 杨昱睿¹ 琚生根¹

1 四川大学计算机学院 成都 610065

2 中国电子科技集团公司第三十研究所 成都 610041

(mxjcdc@163.com)

摘要 生成式摘要自然语言处理中的重要任务,它帮助人们从海量文本中提取简洁而重要的信息。目前主流的生成式摘要模型是基于深度学习的序列到序列模型,这类模型生成的摘要质量更高。但由于缺乏对原文中关键词和句子之间的依赖关系的关注,现有模型生成的摘要仍然存在语义不明、重要信息含量低等问题。针对这个问题,提出了一种基于关键词异构图的生成式摘要模型。该模型通过从原始文本中提取关键词,将其与句子共同作为输入构建异构图,进而学习关键词和句子之间的依赖关系。文档编码器和图编码器分别用于学习文本知识和异构图中的依赖关系。此外,在解码器中采用分层图注意力机制来提高模型在生成摘要时对显著信息的关注。在 CNN/Daily Mail 和 XSum 数据集上进行了充分的实验,实验结果表明,所提模型在 ROUGE 评价指标上有了显著的提升。进一步的人类评估结果显示,所提模型所生成的摘要比基线模型包含更多的关键信息,并具有更高的可读性。

关键词: 生成式摘要; 关键词; 异构图; 图注意力; 序列到序列模型

中图分类号 TP391

KHGAS: Keywords Guided Heterogeneous Graph for Abstractive Summarization

MAO Xingjing¹, WEI Yong², YANG Yurui¹ and JU Shenggen¹

1 College of Computer Science, Sichuan University, Chengdu 610065, China

2 No. 30 Research Institute of CETC, Chengdu 610041, China

Abstract Abstractive summarization is a crucial task in natural language processing that aims to generate concise and informative summaries from a given text. Deep learning-based sequence-to-sequence models have become the mainstream approach for generating abstractive summaries, achieving remarkable performance gains. However, existing models still suffer from issues such as semantic ambiguity and low information content due to the lack of attention to the dependency relationships between key concepts and sentences in the input text. To address this challenge, the keywords guided heterogeneous graph model for abstractive summarization is proposed. This model leverages extracted keywords and constructs a heterogeneous graph with both keywords and sentences as input to model the dependency relationships between them. A document encoder and a graph encoder are respectively used to capture textual information and dependency relationships in the heterogeneous graph. Moreover, a hierarchical graph attention mechanism is introduced in the decoder to improve the model's attention to significant information when generating summaries. Extensive experiments on the CNN/Daily Mail and XSum datasets demonstrate that the proposed model outperforms existing methods in terms of the ROUGE evaluation metric. Human evaluations also reveal that the generated summaries by the proposed model contain more key information and are more readable compared to the baseline models.

Keywords Abstractive summarization, Keywords, Heterogeneous graph, Graph attention, Sequence to sequence model

1 引言

文本摘要是自然语言处理领域的重要任务,它通过算法自动地将输入文本提炼成简短摘要,帮助用户通过摘要准确了解原始文章的核心内容,并且能为其他任务(如信息检索、舆情分析、内容审核等)提供便利。从实现方法来看,文本

摘要方法可分为两类,即抽取式^[1-2]和生成式^[3-4]。其中抽取式方法是从原文中选取评分最高的前几句作为最终摘要,因此语句通畅,但是信息往往存在冗余。生成式方法则是模型从输入的原始文档中学习信息后生成摘要,它更接近人类撰写摘要的过程,生成的词更加灵活,但其内容和逻辑存在缺陷。随着神经网络的发展,基于深度学习的生成

到稿日期:2023-05-09 返修日期:2023-08-21

基金项目:国家自然科学基金重点项目(62137001)

This work was supported by the Key Program of the National Natural Science Foundation of China(62137001).

通信作者:琚生根(jsg@scu.edu.cn)

式摘要方法受到广泛研究。

基于深度学习的生成式摘要方法可分为3类:1)基于编码器-解码器模型的生成式摘要方法,如基于循环神经网络(RNN)^[5]的模型和基于Transformer^[6]的模型,这类方法通常将输入序列映射到输出序列;2)基于强化学习的生成式摘要方法,如基于策略梯度算法和基于Actor-Critic算法的模型;3)基于对抗生成网络(GAN)^[7]的生成式摘要方法,如基于SeqGAN和基于GANs的变种模型。根据不同的应用场景和需求,可以选择不同的生成式摘要模型。然而,目前的生成式摘要方法仍存在一些问题,例如摘要内容不完整、模糊不清、过分概括等问题。为了解决这些问题,可以关注关键词和句子之间的依赖关系进行改进。

用关键词增强摘要生成是近年来研究的热点。He等^[8]通过一组关键词来控制生成的摘要,将关键词视为额外的指导信息,通过控制信号得到想要的摘要。Li等^[9]也注意到关键词的重要作用,他们采用多任务学习框架,用关键词选择性编码策略对源信息进行过滤,然后动态整合输入句子和关键词的语义,通过双重注意力机制构建上下文表示。这些研究所采用的文本序列整合方式过于简化,无法有效捕捉关键词与原文所有语句之间复杂的依赖关系。因此,一些研究人员开始将图结构运用到摘要生成任务中。Cao等^[10]利用开放的信息提取和依赖性解析技术,从输入文本中提取三元组构成图谱,让生成的摘要更忠于原文。然而,很多研究人员使用的是同构图,即图中的节点类型和关系类型都只有一种。相比之下,包含更多类型节点和边的异构图网络可以融合更多信息,因此具备更高的表达能力。在多文档摘要领域,Li等^[11]将文档的显示图表示合并到文档编码过程中,使得模型能捕获更丰富的跨文档关系。Feng等^[12]使用异构图将大规模常识语料库作为外部知识,提升了对话摘要的精度。但是,这些使用异构图的方式在生成式摘要中尚未充分考虑关键词与句子之间的依赖关系,以及如何以明确的方式对这种关系进行表示。

因此,本文提出了一种基于关键词异构图的生成式摘要模型(Keywords Guided Heterogeneous Graph for Abstractive Summarization, KHGAS)。该模型使用一个文档编码器和一个图编码器来增强原文本信息的表示。其中被输入图编码器中的是本文设计的一种基于关键词构造的异构图,它包括3类节点和2种类型的边。此外,本文在解码器中加入分层图注意力机制,让模型关注到更为重要的信息。同时,在解码阶段再次集成关键词编码,以指导解码器围绕关键词生成摘要。

本文的主要贡献如下:

1)提出了一种基于关键词异构图的生成式摘要模型。该模型利用双编码器和改进的解码器有效地融合文本与图信息,能充分学习到关键词所提供的知识,围绕关键词信息生成精炼的摘要。

2)设计了一种基于关键词构造的异构图,用于显示表示关键词和输入句子之间的依赖关系。将该异构图输入图编码器后可以有效学习到文本的结构信息。此外,解码器中的分层图注意力机制让模型更加关注异构图中的重要信息。

3)本文在CNN/Daily Mail^[13]和XSum^[14]数据集上进行

实验,结果显示本文模型并在ROUGE^[15]指标上优于基线模型。消融实验进一步证明了本文设计的模块的有效性,并通过人工评价验证了模型生成的摘要的可读性。

2 相关工作

生成式摘要是一种文本生成任务,它的目标是自动化地从原始文本中提取出重要信息,并生成简短的、有意义的摘要。在训练阶段,通常使用的是监督学习的方法,使用大量的带有标注的文本作为训练数据,建立起一个模型来预测生成摘要的文本序列。在生成阶段,输入一篇新的未知文本,模型将自动提取其中的关键信息,然后生成一个摘要。近年来,生成式摘要受到广泛研究,有基于统计机器翻译的生成式摘要、基于注意力机制的生成式摘要、基于强化学习及生成对抗网络(GAN)等方法的生成式摘要等。本文模型则是在关键词信息的引导下,基于序列到序列框架和基于图进行摘要生成。

2.1 基于序列到序列框架的摘要生成

序列到序列框架的核心思想是输入序列到输出序列的映射转换,它的提出极大地促进了生成式文本摘要的发展。框架中主要包含编码器和解码器模块,其中编码器主要是为了获得文档的抽象语义表示,解码器逐字输出摘要。随着神经网络的不断发展,以循环神经网络(RNN)^[5]、Transformer^[6]、拷贝和覆盖机制^[16]等为基础的序列到序列框架模型,让摘要生成取得了巨大的进展。Dou等^[17]在基础的编码器解码器结构下,提出了一个通用的、可扩展的引导摘要框架(GSum),它可以有效地将不同类型的外部引导作为输入,从而为学习模型提供一定程度的可控性。Liu等^[3]注意到了序列到序列框架模型在训练中使用的结构化损失函数存在的曝光偏差问题,保留原本的框架而提出一种新的训练范式,该范式假设非确定性分布,以便根据不同的候选摘要的质量分配概率质量。同时序列到序列框架结合BERT^[18],BART^[19],RoBERTa^[20]等预训练语言模型后,在各种数据集上的表现也不断提升,可见序列到序列框架依旧是当前文本摘要模型的主流。然而,序列到序列模型无法处理长距离依赖关系,在处理长文本时可能会遗漏一些重要的内容。因此,将关键词信息作为额外引导,不仅在构图时以关键词为核心,还在解码器中进一步融合关键词信息,使得生成的摘要语义更加明确,包含更多关键词信息。

2.2 基于关键词引导的摘要生成

研究人员注意到关键词对摘要任务的有益作用,常将其作为额外的引导信息^[9,17]辅助摘要生成。Xu等^[21]提出了一种基于多任务学习框架的生成式摘要关键信息引导网络,用多视图注意力引导网络获取原文本和关键信息的动态表示,以指导摘要生成过程。Guan等^[22]提出了一种三编码器模型,将原文上下文、知识结构同主题关键词进行整合,形成一种特殊的线性化知识结构。He等^[23]提出,在测试阶段将控制信号映射到关键词,并探索了关键词和文本提示的组合,以实现摘要的控制生成。但是上述研究仅关注关键词个体对摘要的影响,未考虑贯穿全文的关键词与句子的依赖关系。而基于图的生成式摘要模型可以通过将文本转化为图形结构,显示地构建词句之间的依赖关系,以更全面的方式表示

文本的内容和结构,保留更多的信息。

2.3 基于图的摘要生成模型

早期 TextRank^[24], LexRank^[25] 等图排序算法计算任意句子的相似性,然后对包含文本自身的结构信息的词句进行排序。Mihalcea 等^[24] 构建了一个与文本关联的图,其中图顶点代表要排序的单元,并根据从整个文本中提取的信息,递归地计算文本单元的排名;Wan 等^[26] 进一步提出将文档级别的信息和文档与句子的关系共同纳入图的排序过程中。近年来,随着图神经网络的兴起,基于 GNN, GCN^[27] 等框架的文本摘要模型也受到广泛关注。Yasunaga 等^[28] 设计了一种基于图的抽象摘要注意力机制;Wang 等^[29] 聚焦于 GNN 中的多种消息传递机制来抽取摘要;Jin 等^[30] 提出的 SemSUM 将输入句子的谓词-参数结构的语义依赖图纳入神经抽象摘要模型中,该模型提高了语义相关性。然而,这些图相关模型仅根据单词或句子来构建文档图,缺乏对关键词和句子依赖关系的

关注,导致生成的摘要可读性不高。因此,本文同时引入了关键词节点、句子节点和关键短语节点来构建异构图,让模型学习关键词与句子的依赖关系,确保摘要围绕关键词生成。

3 本文模型

生成式摘要任务是将一个长度可变的原文本输入序列 $X=(x_1, x_2, \dots, x_n)$, 经过模型训练后生成另一个摘要序列 $Y=(y_1, y_2, \dots, y_m)$, n 为输入文本的长度, m 为输出摘要的长度,并且规定 $m \ll n$ 。

本文提出的基于关键词异构图的生成式摘要模型包含两个编码器和一个解码器,如图 1 所示,分别是处理原文本序列信息的文档编码器、学习异构图信息的图编码器以及在关键词引导下的解码器。接下来,本章将介绍 KHGAS 模型的各种细节,包括如何构造基于关键词的异构图、文档编码器、图信息编码器和关键词引导的解码器的具体设计。

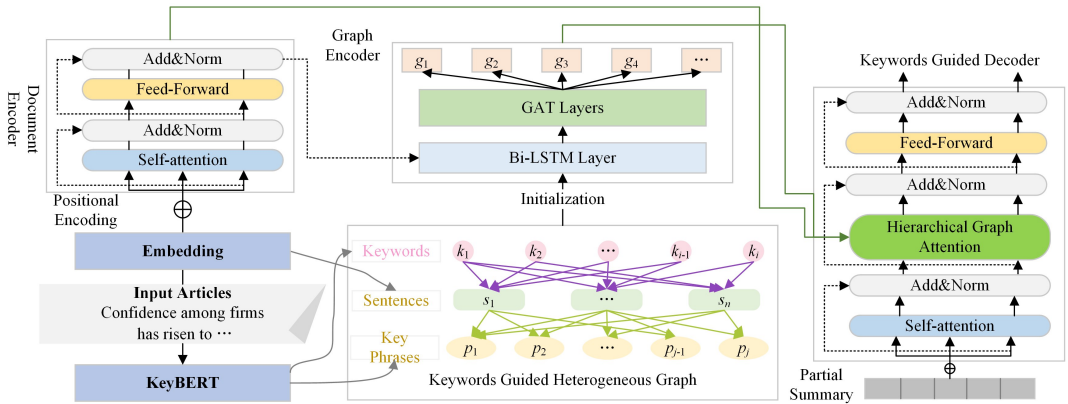


图 1 基于关键词异构图的生成式摘要模型图

Fig. 1 Model graph of keywords guided heterogeneous graph for abstractive summarization

3.1 构造基于关键词的异构图

本文基于关键词的异构图的构造过程如图 2 所示。首先输入文本在预处理阶段会进行语句的划分,得到每个语句的序列

编码。考虑到关键词在文章中起到的重要作用,本文选取由 KeyBERT^[31] 模型抽取出来的得分靠前的关键词和关键短语。最终将关键词和关键短语节点与包含它们的句子节点相连接。

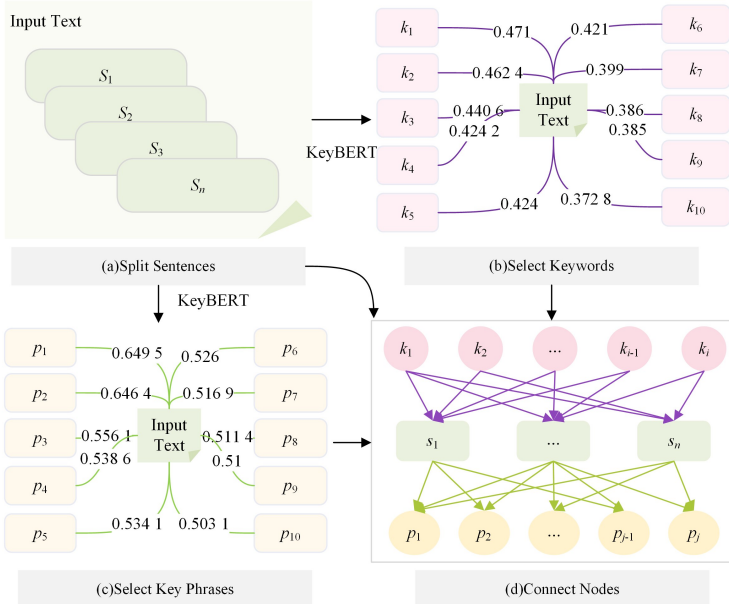


图 2 基于关键词构造的异构图

Fig. 2 Heterogeneous graph constructed based on keywords

基于关键词的异构图被定义为一个有向图 $G=(V,E)$, 其中每个节点 $v \in V$, 每条边 $e \in E$ 。本文的异构图共有 3 种类型的节点, 即 $V=V_K \cup V_S \cup V_P$, 其中 $V_K=\{k_1, k_2, \dots, k_i\}$ 表示关键词节点, $V_S=\{s_1, s_2, \dots, s_n\}$ 表示句子节点, $V_P=\{p_1, p_2, \dots, p_j\}$ 表示关键词节点; 还包括两种类型的边关系 $E=E_{KS} \cup E_{SP}$, $e_{ks}^a \in E_{KS} (a \in \{1, \dots, i\}, b \in \{1, \dots, n\})$ 为关键词和句子之间的关系, $e_{sp}^b \in E_{SP} (b \in \{1, \dots, n\}, c \in \{1, \dots, j\})$ 即句子节点和关键词节点间的关系。

KeyBERT 是一种很小且易于使用的关键词提取技术, 它基于一种假设: 关键词与文档在语义表示上是一致的, 使用 Bert 嵌入和简单的余弦相似性来查找文档中与文档本身最相似的子短语, 能够得到较好的结果。为了避免引入冗余信息, 本文只保留不是停用词的关键词, 并按照它们在原文中出现的顺序排列。此外, 近似得分越小表明该关键词的重要性越低, 经过实验对比, 本文将近似得分低于 0.3 的词或短语舍弃。句子节点即为源文本以句号为分隔的 n 个句子序列。

基于关键词的异构图包括两种类型的边, 它们表示包含和被包含关系, 如果关键词或短语在某个句子中出现, 则它们有相连的边, 也就是说, 某句话描述的关键内容越多, 与它相连的边也就越多, 这样可以很容易地定位到用于书写摘要的重要句子, 同时能让模型捕捉到关键信息的转移和关联。因关键词和短语常常贯穿全文始终, 基于关键词构造的异构图实现了全文信息的关联, 改善了距离较远的句子之间不互通的问题, 我们为输入的每一篇文档构建这样一个基于关键词的图表示。

3.2 文档编码器

文档编码器的作用是读取原文单词序列 X 并构建其上下文表示, 由此可以更好地按顺序表示局部特征。本文采用 BART 作为文档编码器, 它是一种基于 Transformer 架构的预训练语言模型, 具有强大的自然语言处理能力。其采用双向编码, 能够同时考虑文本的前向和后向上下文信息, 从而更全面地捕捉文本的语义和结构。使用 BART 模型作为文档编码器能够为生成式摘要任务提供强大的语言建模和编码能力, 从而有效提高摘要质量和可读性。

本文在每句话的开头和结尾分别插入 [CLS] 和 [SEP] 以间隔句子, 用位置编码 l_i 表示单词在句子中的位置, 每个输入语句 x 通过学习嵌入得到向量表示 e_x , 最终输入句子的向量表示则为 $s=e_x+l_i$ 。将输入表示提供给基于 BART 的文档编码器进行训练 $\{h_{10}, h_{11}, \dots, h_m\} = \text{BART}(\{s_{10}, s_{11}, \dots, s_m\})$, 其中 s_{ij} 表示第 i 个句子中的第 j 个单词, s_{10}, s_m 分别是 [CLS] 和 [SEP] 的表示。对应句子的上下文表示则为 [CLS] 隐状态的集合 $H_S=\{h_{10}, h_{20}, \dots, h_{n0}\}$ 。之后将文档编码器的最后一层输出作为字符嵌入, 它将被送入单层双向 LSTM, 从而生成在时间步 K 的字符隐状态 h_K 。

3.3 图编码器

本文使用双向 LSTM 对实体进行编码, 并应用图注意力网络来迭代和更新图的关系信息。在经过文本编码器获得字符级别的表示后, 我们进一步异构图并将其送入图编码器, 以获得图的节点表示。原始的有向边不足以学习反向信息, 因此本文在图中添加了反向边和自循环边。为更好地学习异构图

的信息, 具体来说, 本文基于字符的表示和字符到节点的对齐信息来初始化图中的节点表示。初始化后应用图编码器对异构图中的显示语义关系进行建模, 并应用相关图增强方法来学习图所包含的隐式结构。

在基于关键词的异构图中每个节点通常被多次提及, 因此本文遵循 Li 等^[32] 提出的方法, 使用字符平均嵌入来初始化节点表示 v_i 。因为关键词和句子节点含有多个单词, 所以本文用 Bi-LSTM 作为节点编码器, 对输入节点进行前向和后向的编码, 前后向链接后得到最终初始化的节点表示 h_i^0 , 它将传递给图注意力层进行训练更新以学习更高级的图表示。另外, 将节点被提到的次数作为额外的编码添加到 v_i 中, 以标注该节点的重要性。

本文的图编码器是 Kedzioriski 等^[33] 提出的方法的改进, 添加了层之间残差链接的图注意力网络, 获得了图的全局上下文表示。每个节点 v_i 由其相邻节点的加权平均值表示。

$$\hat{v}_i = v_i + \left\| \sum_{v_j \in \mathcal{N}(v_i)} \alpha_{i,j}^n \mathbf{W}_{0,n} v_j \right\| \quad (1)$$

$$\alpha_{i,j}^n = \text{softmax}(\mathbf{W}_{1,n} v_i)^\top (\mathbf{W}_{2,n} v_j) \quad (2)$$

其中, $\mathcal{N}(v_i)$ 表示图 G 中 v_i 的邻居集合, 包括 v_i 本身, \mathbf{W}_* 是可训练矩阵参数, $\left\| \sum_{v_j \in \mathcal{N}(v_i)} \right\|$ 表示 N 个头的拼接, 每个头产生一个与 v_i 同维度的向量。本文设置 $N=4$, 并在两层 GAT 网络中进行实验, 以便每个节点通过迭代更新获得更多全局表示。每篇文档图都将获得自己的最终图表示 g_i 。

$$g_i^l = \text{FFN}(\text{LN}(g_i^{l-1} + \sum_{v_j \in \mathcal{N}(v_i)} \alpha_{i,j}^l g_j^{l-1})) \quad (3)$$

其中, g_i^l 表示在第 l 次迭代中的图表示, FFN 表示一个两层的前馈神经网络, LN 表示进行层归一化操作。

3.4 摘要生成解码器

文本和图表示能给摘要生成带来不同方面的优势, 文档的字符表示擅于捕捉局部特征, 而图表示则提供了全局语义关系和更抽象层面的特征。解码器的初识隐状态 $d_0 = \tanh(\mathbf{W}_3 \cdot [h_k \parallel g_i])$ 是由两个编码器在最后一个时间步的隐状态转换而来的。为了更好地融合和处理这两种表示, 本文设计了基于 BART 解码器的在关键词指导下的图解码器。因为其他部分与传统预训练解码器区别不大, 接下来主要介绍关键词和分层注意力机制的具体细节。

称其为基于关键词指导的解码器的原因是, 本文将图中所有关键词节点表示的均值池化作为解码步骤的先验知识, 即主题信息表示 $\bar{\kappa}$:

$$\bar{\kappa} = \frac{1}{n} \sum_{i=1}^n v_{k_i} \quad (4)$$

来自文档编码器和图编码器的信息都将被送入解码器进行处理, 而其重要程度显然应该根据上下文内容进行自我调整。因此, 除了在编码过程中应用注意力机制外, 本文在解码器中利用分层注意力机制来集成图文上下文信息。不同于 Li 等在全局和局部图进行分层注意力聚合的方式, 本文分层注意力的重点在于将文本信息、图信息和关键词信息进行聚合。

文档和图注意力分别表示为 α_r^t 和 α_g^t , 则上下文向量计算为 $c_r^t = \sum_{i=0}^t \alpha_r^i h_r^i, r \in \{x, g\}$ 。在时间步 t 的解码器隐状态 $d_t = f(d_{t-1}, c_{t-1}^r, c_{t-1}^g, y_{t-1})$, y_{t-1} 为解码器的输入, 函数 $f(\cdot)$ 为单项 LSTM。分层注意力机制下的聚合注意力为:

$$z^r = \mathbf{u}^T \tanh(\mathbf{W}_i^r c_i^r + \mathbf{W}_d^r d_i + \mathbf{W}_k^r \bar{\kappa} + z_i^r) \quad (5)$$

$$\zeta^r = \text{softmax}(z^r), r \in \{x, g\} \quad (6)$$

其中, ζ^r 为 3 种聚合成分的层次注意力权重, 最终聚合的上下文文表示为:

$$c_i^* = \sum_{r \in \{x, g\}} \zeta^r c_i^r \quad (7)$$

因此, c_i^* 可以编码来自两个编码器模型中重要的上下文文表示。通过关键词的引导和分层注意力的编码, 解码器可以更有效地利用源信息。

3.5 训练目标

对于给定的输入文档, 我们的目标是尽可能地生成与原始文本相关且具有意义的摘要。为了衡量模型生成的摘要与目标摘要之间的差异, 以便调整模型参数以提高生成摘要的质量, 本文使用负对数极大似然损失函数:

$$\text{loss} = -\frac{1}{|D|} \sum_{(x, y) \in D} \log p(y|x; \theta) \quad (8)$$

其中, D 为输入文档集, x 和 y 分别为原文本和参考摘要, θ 为模型参数。最小化该函数即可使模型预测的概率分布与实际下一个单词出现的概率分布之间的差异最小, 从而最大限度地提高生成摘要的质量。

4 实验

4.1 数据集与评价指标

本文实验主要使用了两个在自动文本摘要领域流行的开放数据集 CNN/Daily Mail 和 XSum。CNN/DM 是一个大型新闻数据集, 其中每篇文章都附有高质量摘要, 用于监督式学习中的训练和评估。这些文章的主题涵盖了政治、科技、娱乐等多个领域, 摘要长度大约为 3~4 句话。XSum 是由英国广播公司(BBC)文章和附带单句摘要组成的高度抽象的数据集。其中每篇文章前面都有一个介绍性的句子, 并且这个句子是由文章作者写的很专业的摘要。对于这两个数据集, 本文遵循了 Nallapati 等^[13]的预处理步骤和实验设置。对于 CNN/DM, 其训练集、验证集和测试集分别包含 287188, 13367 和 11490 个样本。对于 XSum, 对应分别有 204045, 11332, 11334 个样本。CNN/DM 和 XSum 的最小摘要长度分别为 56 和 11。本文使用 ROUGE 来评估摘要质量。ROUGE 指标包括 ROUGE-1, ROUGE-2 和 ROUGE-L, 分别用于衡量生成的摘要与参考摘要的 unigram, bigram 和最长公共子序列(LCS)方面的重合程度。通常情况下, ROUGE-1 和 ROUGE-2 被广泛用于自动文本摘要任务的评估, 其中 ROUGE-1 更注重生成的摘要是否涵盖了关键信息, 而 ROUGE-2 更注重生成的摘要是否保留了重要的词序信息。

4.2 参数设置

KHGAS 是基于序列到序列框架的训练, 本文使用 BART 框架的基本版本为所有实验提取词汇特征。在对语料库文章进行预处理时, 将输入文章截断为 512 字, 解码器使用一个 6 层的 Decoder。对于 CNN/DM 和 XSum, 本文遵循与 Lewis 等^[19]相同的微调设置, 只是本文对每个数据集使用 40000 和 20000 训练步骤。本文使用 Adam 作为优化器, 学习率为 2×10^{-4} , 总训练次数为 30, 批处理大小设置为 8。本文

使用 256 维隐状态的双向 LSTM, 即前向后向分别 128 个维度。在 GAT 中, 取 GAT 层数为 2, 设置主题节点注意力数量为 4, 句子节点注意力数量为 6, 隐藏大小为 128。为避免过拟合, GAT 中的 Dropout 率为 0.6, 模型其他部分的 dropout 率为 0.1。在训练过程中, 如果模型性能下降, 则将学习率减半, 并使用减半的学习率进行微调。利用 KeyBERT 模块各选取 10 个基础关键词和关键短语, 经过对比发现, 使用 paraphrase-mpnet-base-v2 模型抽取的关键词和关键短语与原文主旨的相关性最高, 同时会将后出现的与之前关键词字母重叠率高于 80% 的单词或短语删除, 保留其中分数最高的一个。

4.3 基线模型

实验中, 将本文的 KHGAS 模型与近年来提出几个的强基线模型进行比较。

LEAD-3(2016)^[11]通过抽取文章的前三句作为文章的摘要, 这种方法简单而有效, 是常用的抽取式摘要基线。

PTGen+Cov(2017)^[16]在基于注意力机制的序列到序列模型的基础上增加了拷贝和覆盖机制, 有效缓解了未登录词和生成重复的问题。

KIGN+Predicting-guide(2018)^[33]引入关键信息引导网络(KIGN), 将关键词编码为关键信息表示, 并将其集成到生成式模型中, 利用预测引导机制预测最终摘要中覆盖关键信息的程度, 以进一步指导摘要的生成。

KIGN+Multi-task(2020)^[21]在 KIGN 的基础上将抽取模型和生成模型融合为一个端到端的模型, 并在生成模块中加入原文和关键词的动态表示, 在多任务学习框架下指导摘要生成。

BertSumAbs(2019)^[34]在 BERT 上进行微调后用于生成摘要。

MASS(2019)^[35]在编码器解码器框架下进行语句生成, 在编码器中将一个带有随机掩码的片段作为输入, 而用解码器来预测这个掩码片段, 从而增强语言建模的能力。

PEGASUS_{BASE}(2020)^[36]在大量文本语料库上预训练大型 Transformer 的编码器解码器模型, 并在输入文档中删除或屏蔽重要句子, 从剩余句子中生成一个输出序列。

BART(2020)^[19]是一种用于预训练序列到序列模型的去噪自动编码器。它首先用任意噪声函数破坏文本, 最后学习一个模型来重建原始文本, 它对文本生成任务特别有效。

GSUM+Keyword(2021)^[17]模型在生成输出时同时处理原文档和关键词引导信号, 以约束模型的输出。

SKGSUM(2021)^[37]将外部语义知识合并到模型框架中, 提出了一种基于语义知识图的单文档摘要抽象模型。该模型将句子和实体作为节点, 捕获不同文本级别单元之间的关系, 并关注源文档中的显著内容来指导摘要生成过程。

GATSUM(2022)^[38]是基于图的主题感知摘要模型, 使用神经主题模型来查找潜在的主题信息。该模型关注文档级别的特征以生成摘要。

4.4 实验结果与分析

为了深入了解 KHGAS 模型, 除了两个公开数据集上进行基础的自动评估实验外, 本文还补充了消融实验和人工

评价实验,此外还增设了不同类型图在使用本文模型时的效果对比。

4.4.1 自动评价结果

本节对本文提出的模型进行评估,通过对比模型生成摘要句的准确性来评估模型的效果。表1和表2分别列出了在CNN/DM和XSum数据集上本文提出的KHGAS模型与对比模型的实验结果。在CNN/DM数据集上,本文模型在1-gram、2-gram和最长子序列的评估上均取得了最好的性能。与基于Bert的预训练模型BertSumAbs相比,KHGAS模型在R-1、R-2和R-L上分别提升了3.46、2.49和2.88个百分点,这说明使用更强大的预训练模型能得到更好的文本表示,这也是领域发展的一大趋势。本文模型相比BART模型也有更好的表现,证明本文在编码器和解码器上所做的设计和改进行是有效的。此外,为了进一步与BART模型生成的摘要进行比较,我们设置了人工评价,将在下一节进行详细阐述。与同样利用了图结构的GATSUM模型相比,本文模型有更高的指标,说明本文构造的异构图以及分层图注意力机制能更有效地学习图的信息。

表1 CNN/DM数据集上的自动评价结果

Table 1 Automatic evaluation results on CNN/DM dataset

Model	R-1	R-2	R-L
LEAD-3	40.42	17.62	36.67
PTGen+Cov	39.81	17.28	36.38
KIGN+Predicting-guide	38.95	17.12	35.68
KIGN+Multi-task	40.34	17.70	36.57
BertSumAbs	41.72	19.39	38.76
MASS	42.12	19.50	39.01
PEGASUS _{BASE}	41.79	18.81	38.93
BART	44.16	21.28	40.90
GSUM+keyword	42.21	19.36	39.23
SKGSUM	41.61	18.55	38.30
GATSUM	44.46	21.32	39.84
KHGAS(Ours)	45.18	21.85	41.64

表2 XSum数据集上的自动评价结果

Table 2 Automatic evaluation results on XSum dataset

Model	R-1	R-2	R-L
LEAD-3	16.30	1.60	11.95
PTGen+Cov	28.10	8.02	21.72
BertSumAbs	38.76	16.33	31.15
MASS	39.75	17.24	31.95
PEGASUS _{BASE}	39.79	16.58	31.70
BART	45.14	22.27	37.25
SKGSUM	33.59	13.33	26.35
GATSUM	44.60	21.53	36.66
KHGAS(Ours)	45.22	22.32	37.11

XSum数据集的文章和摘要更短、更抽象,模型需要精炼信息并生成包含关键信息的摘要,因此在这个数据集上更倾向于生成摘要片段。KHGAS模型在XSum数据集上的性能优于抽取模型,也优于基础的预训练模型。BART通过设计自监督任务同时预训练了编码器和解码器,在生成式任务上表现出色。而本文模型在R-L指标上取得了与BART相近的效果,原因是本文模型在关键词、关键短语这类片段性的内容上具有更高的注意力权重。在R-1和R-2指标上取得了最好的效果,说明KHGAS所生成的摘要能包含更多的信息量,这是因为本文所构造的基于关键词的异构图让模型整合

了更多的信息,利于囊括关键信息的输出。本文模型在生成文本的能力上较一般的基于图的模型提升更大,这说明基于关键词异构图的模型在文本理解上起到了一定的作用。KHGAS的良好性能证实了引入层次图注意力和关键词的先验知识来提升摘要质量的重要性。

4.2.2 人工评价

自动评价并不能完全体现一段摘要的质量,因为它仅是使用词共现率进行评估。因此,本文进一步进行了人工评价,以分析生成的摘要的信息量和流畅性,以及调查不同模型所产生的事实不一致问题。从CNN/DM测试集中抽取了50篇文章,并邀请了3位流利使用英语的研究人员对KHGAS模型、BART模型生成的摘要以及参考摘要进行评分,它们出现的顺序是随机的。阅读完这些文章后,每位评委根据自己的观感,对摘要的信息量(Inf \uparrow)、流畅度(Flu \uparrow)给出1~5分的评分,分数越高,质量越高。此外,针对事实不一致问题,评委需要分别用1和0分别标记摘要是否存在:1)与原文信息不符的内容(Hal \downarrow);2)违背客观事实的内容(Err \downarrow)。这两项分数越低,说明错误越少。最终评分结果如表3所列。

表3 人工评价结果

Table 3 Results of human evaluation

Source	Inf \uparrow	Flu \uparrow	Hal \downarrow / %	Err \downarrow / %
Human	4.47	4.65	21	10
BART	4.25	4.66	16	14
KHGAS	4.31	4.35	15	9
KHGAS-graph	3.94	3.65	10	22

从表3可以看出,在信息量和流畅度方面,本文的KHGAS模型比没有图信息的变体所获得的分数更高,这证明了利用异构图信息的有效性。经过完整模型训练的输出摘要具有与BART相似的流畅度和更多的信息量,并且在真实内容的错误率上最低。总体来说,对于事实一致性错误,与没有图信息的模型相比,本文的图和关键词信息增强的模型在这一方面产生的错误显著减少。这意味着KHGAS模型在文本理解上有一定的提升,异构图增强模型可以提高摘要的可信度。

4.4.3 消融实验

通过对KHGAS模型进行一系列消融实验来分析基于关键词的异构图、关键词引导解码组件以及分层图注意力机制的引入对模型的影响,消融结果如表4和表5所列。其中,KHGAS为本文提出的模型,w/o graph表示在模型中去掉基于关键词的异构图及图编码模块,w/o keywords guided表示在模型中去掉关键词先验信息模块,w/o hierarchical graph attention表示在模型中去掉分层图注意力机制,w/o KeyBERT表示不使用KeyBERT进行关键词抽取,而使用TextRank得到关键词进行后续构图。

表4 CNN/DM数据集上的消融实验结果

Table 4 Results of ablation experiments on CNN/DM

Model	R-1	R-2	R-L
KHGAS	45.18	21.85	41.64
w/o graph	44.39	21.06	41.02
w/o keywords guided	45.02	21.43	41.36
w/o hierarchical graph attention	44.68	21.18	41.15
w/o KeyBERT	44.86	21.25	41.28

表 5 XSum 数据集上的消融实验结果

Table 5 Results of ablation experiments on XSum

Model	R-1	R-2	R-L
KHGAS	45.92	22.32	37.11
w/o graph	44.58	21.42	36.61
w/o keywords guided	45.21	22.13	36.94
w/o hierarchical graph attention	44.96	21.87	36.81
w/o KeyBERT	45.07	21.96	36.89

从表 5 可以看出,在完整模型的基础上,减去基于关键词的异构图后,在 CNN/DM 数据集上 ROUGE-1 得分降低了 1.74%,表明源文档通过异构图谱获得的围绕关键词的上下文信息有助于提升模型的效果。当减去关键词引导的解码器信息之后,模型效果不佳,这说明通过将关键词的信息注入编码器和解码器共同学习,可以在一定程度上提高模型对文档的理解力,进一步辅助模型提升摘要生成的能力。同样地,当减去分层图注意力机制后模型得分降低,证明给更重要的内容赋予更高的注意力权重再进行迭代训练,可以让模型在训练过程中产生更优的结果。当使用传统的 TextRank 算法抽取关键词时评分降低,这是因为 KeyBERT 是经过预训练的模型,比经典算法效果更优。若今后有更优质的关键词抽取方法,则能使本文模型性能获得进一步提升。通过上述消融实验分析,说明本文方法对模型均有正向影响,并且在包含所有组件时效果最佳,从而验证了本文提出的 KHGAS 模型的有效性。

4.4.4 图类型的影响

为了验证本文提出的基于关键词的异构图的有效性,在 Li 等^[1]的研究的启发下,在 CNN/DM 测试集上将本文构建的基于关键词的异构图替换为相似度图(Similarity)、主题图(Topic)和实体图(Entity)。相似度图是根据文本中的 TF-IDF 余弦相似度构建的,主题图是基于 LDA 主题模型来获取段落主题关系而构建的,而实体图则是由 OpenIE 工具抽取原文的事实三元组构建的图,其结果如图 3 所示。

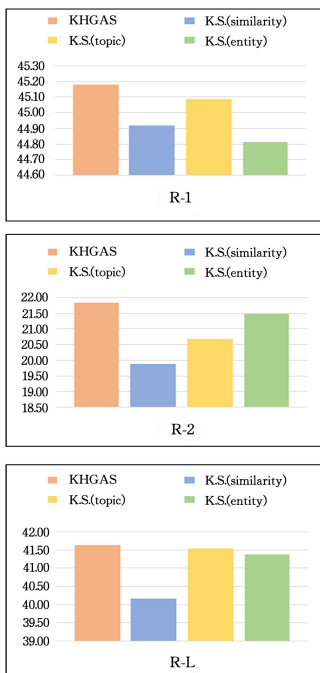


图 3 图类型的影响实验结果对比

从图 3 可以看出,主题图在 R-1 和 R-2 的性能上优于相似图,而实体图在 R-2 和 R-L 上的性能更好,也就是说,关系越丰富的图对摘要生成任务越有帮助。而本文基于关键词的异构图在 3 项评分上均处于前列,说明基于关键词构建的异构图包含了丰富信息,并且保持了远距离依赖关系的图。此外,不同类型的图在本模型上均能取得较好的实验结果,说明本文模型具有一定的泛化能力,模型框架具有普适性。

结束语 本文提出了一种基于关键词异构图的生成式摘要模型。该模型是基于源文本的关键词和关键短语构建异构的知识图谱,从而获得源文本上下文表示的方法。在图编码器中通过图注意力网络增强图的表示,促进相关实体之间的联系以及对上下文的理解。在解码阶段,不仅有从文档编码器获得的文本表示,还有从图编码器获得的图表示信息,同时将关键词作为先验知识以增强解码器的解码能力。此外,解码器的分层图注意力机制,基于文本和图信息不同的权重,增强了模型对源文本的理解能力,让模型同时学习到重要知识。采用迭代的目标优化,在不同数据集上的实验结果表明本文提出的关键词异构图的摘要生成方法可以有效生成质量更高的文本摘要。在未来工作中,一方面可以尝试设计更加强大、可靠的摘要生成方法,以帮助模型生成与原文和常识更相符的摘要;另一方面,模型轻量化和高效性也将成为研究方向之一,从而让基于深度学习的自动摘要技术更好地落地,帮助人们快速获取质量不错的文本摘要。

参考文献

- [1] HEWETT F, STEDE M. Extractive Summarisation for German-language Data: A Text-level Approach with Discourse Features [C]// Proceedings of the 29th International Conference on Computational Linguistics. International Committee on Computational Linguistics, 2022; 756-765.
- [2] LI J, ZHANG C, CHEN X, et al. Survey on Automatic Text Summarization [J]. Journal of Computer Research and Development, 2021, 58(1): 1-21.
- [3] LIU Y, LIU P, RADEV D, et al. 2022. BRIO: Bringing Order to Abstractive Summarization [C]// Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). Association for Computational Linguistics, 2022; 2890-2903.
- [4] LIU X, WANG H, WU J. GAN and Chinese WordNet Based Text Summarization Technology [J]. Computer Science, 2022, 49(12): 301-304.
- [5] MIKOLOV T, KARAFIÁT M, BURGET L, et al. Recurrent neural network based language model [C]// INTERSPEECH-11th Annual Conference of the International Speech Communication Association. 2010; 1045-1048.
- [6] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C]// Advances in Neural Information Processing Systems. 2017; 5998-6008.
- [7] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks [J]. Communications of the ACM, 2020, 63(11): 139-144.
- [8] HE J, KRYSZCINSKI W, MCCANN B, et al. CTRLsum: To-

Fig. 3 Comparison of experimental results on the effect of graph type

- wards Generic Controllable Text Summarization[C]// Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing. Association for Computational Linguistics, 2022; 5879-5915.
- [9] LI H, ZHU J, ZHANG J, et al. Keywords-Guided Abstractive Sentence Summarization[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2020; 8196-8203.
- [10] CAO Z, WEI F, LI W, et al. Faithful to the Original: Fact Aware Neural Abstractive Summarization [C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2018.
- [11] LI W, XIAO X, LIU J, et al. Leveraging Graph to Improve Abstractive Multi-Document Summarization [C]// Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. Association for Computational Linguistics, 2020; 6232-6243.
- [12] FENG X, FENG X, QIN B. Incorporating Commonsense Knowledge into Abstractive Dialogue Summarization via Heterogeneous Graph Networks[C]// China National Conference on Chinese Computational Linguistics. Springer, CCL 2021; Chinese Computational Linguistics, 2021; 127-142.
- [13] NALLAPATI R, ZHOU B, SANTOS C, et al. Abstractive Text Summarization using Sequence-to-sequence RNNs and Beyond [C]// Proceedings of the 20th SIGNLL Conference on Computational Natural Language Learning. Association for Computational Linguistics, 2016; 280-290.
- [14] NARAYAN S, COHEN S, LAPATA M. Don't Give Me the Details, Just the Summary! Topic-Aware Convolutional Neural Networks for Extreme Summarization[C]// Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. Association for Computational Linguistics, 2018; 1997-1807.
- [15] LIN C. ROUGE: A Package for Automatic Evaluation of Summaries[C]// Text Summarization Branches Out. Association for Computational Linguistics, 2004; 74-81.
- [16] SEE A, LIU P, MANNING C. Get To The Point; Summarization with Pointer-Generator Networks[C]// Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 1; Long Papers). Association for Computational Linguistics, 2017; 1073-1083.
- [17] DOU Z, LIU P, HAYASHI H, et al. GSum: A General Framework for Guided Neural Abstractive Summarization[C]// Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics; Human Language Technologies. Association for Computational Linguistics, 2021; 4830-4842.
- [18] DEVLIN J, CHANG M, LEE K, et al. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding [C]// Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics; Human Language Technologies, Volume 1 (Long and Short Papers). Association for Computational Linguistics, 2019; 4171-4186.
- [19] LEWIS M, LIU Y, GOYAL N, et al. BART: Denoising Sequence-to-Sequence Pre-training for Natural Language Generation, Translation, and Comprehension[C]// Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. Association for Computational Linguistics, 2020; 7871-7880.
- [20] LIU Y, OTT M, GOYAL N, et al. Roberta: A robustly optimized bert pretraining approach[EB/OL]. (2019-07-26) [2022-07-28]. <https://doi.org/10.48550/arXiv.1907.11692>.
- [21] XU W, LI C, LEE M, et al. Multi-task learning for abstractive text summarization with key information guide network [J/OL]. EURASIP Journal on Advances in Signal Processing 2020. <https://doi.org/10.1186/s13634-020-00674-7>.
- [22] GUAN S, ZHU P, WEI Z. Knowledge and Keywords Augmented Abstractive Sentence Summarization[C]// Proceedings of the Third Workshop on New Frontiers in Summarization, Online and in Dominican Republic. Association for Computational Linguistics. 2021; 25-32.
- [23] HE J, KRYSCINSKI W, MCCANN B, et al. CTRLsum: Towards Generic Controllable Text Summarization[C]// Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing, Abu Dhabi, United Arab Emirates. Association for Computational Linguistics. 2022; 5879-5915.
- [24] MIHALCEA R, TARAU P. Textrank: Bringing Order into Text [C] // Empirical Methods in Natural Language Processing (EMNLP). ACL, 2004; 404-411.
- [25] ERKAN G, RADEV D R. Lexrank: Graph-based Lexical Centrality as Saliency in Text Summarization [J]. Journal of Artificial Intelligence Research, 2004, 22, 457-479.
- [26] WAN X, XIAO J. Single Document Keyphrase Extraction Using Neighborhood Knowledge [C]// Proceedings of the AAAI Conference on Artificial Intelligence. AAAI, 2008; 855-860.
- [27] KIPF T, WELLING M. Semi-Supervised Classification with Graph Convolutional Networks[C]// Proceedings of the 5th International Conference on Learning Representations. ICLR 2017.
- [28] YASUNAGA M, ZHANG R, MEELU K, et al. Graph-based Neural Multi-Document Summarization[C]// Proceedings of the 21st Conference on Computational Natural Language Learning (CoNLL 2017). Vancouver, Canada; Association for Computational Linguistics, 2017; 452-462.
- [29] WANG D, LIU P, ZHENG Y, et al. Heterogeneous graph neural networks for extractive document summarization[C]// Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, Online. Association for Computational Linguistics; 2020; 6209-6219.
- [30] JIN H, WANG T, WAN X. Semsum: Semantic dependency guided neural abstractive summarization[C] // Proceedings of the AAAI Conference on Artificial Intelligence. AAAI, 2020; 8026-8033.
- [31] GROOTENDORST M. KeyBERT: Minimal keyword extraction with BERT [EB/OL]. <https://doi.org/10.5281/zenodo.4461265>.
- [32] LI C, XU W, LI S, et al. Guiding Generation for Abstractive

Text Summarization Based on Key Information Guide Network [C]//Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 2 (Short Papers), New Orleans, Louisiana. Association for Computational Linguistics, 2018;55-60.

[33] KEDZIORSKI R, BEKAL D, LUAN Y, et al. Text Generation from Knowledge Graphs with Graph Transformers [C]// Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Association for Computational Linguistics, 2019;2284-2293.

[34] LIU Y, LAPATA M. Text Summarization with Pretrained Encoders [C]// Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP). ACL, 2019;3730-3740.

[35] SONG K, TAN X, QIN T, et al. MASS: Masked Sequence to Sequence Pre-training for Language Generation [C]// International Conference on Machine Learning. PMLR, 2019;5926-5936.

[36] ZHANG J, ZHAO Y, SALEH M, et al. Pegasus: Pre-training with extracted gap sentences for abstractive summarization [C]// Proceedings of the 37th International Conference on Ma-

chine Learning (ICML'20). JMLR. org, 2020;11328-11339.

[37] JI X, ZHAO W. SKGSUM: Abstractive Document Summarization with Semantic Knowledge Graphs [C]// 2021 International Joint Conference on Neural Networks (IJCNN). Shenzhen, China, 2021;1-8.

[38] JIANG M, ZOU Y, XU J, et al. GATSum: Graph-Based Topic-Aware Abstract Text Summarization [J]. Information Technology and Control, 2022;51(2), 345-355.



MAO Xingjing, born in 1998, postgraduate, is a member of CCF (No. K9114G). Her main research interests include natural language processing and text summarization.



JU Shenggen, born in 1970, Ph.D., professor, Ph.D supervisor, is a member of CCF (No. 14364S). His main research interests include data mining, natural language processing and knowledge graphs.

(责任编辑:喻黎)

CCF 算法大赛 (CAC) 启动会在京召开

2024年6月7日, CAC启动会在北京中科院计算所举行。CCF会士、前理事长、中国工程院院士, 清华大学教授郑纬民担任今年的大会主席, CCF常务理事徐建昌主持了本次启动会。这次会议的召开标志着CAC筹备工作正式全面启动。

CCF秘书长唐卫清在会上致辞, 详细阐述了推动CAC的初衷, 并对CAC提出了总体计划和要求。唐卫清指出, CAC是CCF为提升算法人才培养和产学研合作而举办的赛事, 旨在打造一个具有国家影响力的算法竞赛品牌。希望通过本次CAC, 取得良好的口碑, 促进算法研究、设计和应用的普及和推广, 为未来培养出更多的算法人才。CAC下设组织委员会、技术委员会和竞赛办公室。组织委员会主席由徐建昌担任, 负责制定规则、赛点管理、比赛组织、经费筹措、违规者处罚等工作。技术委员会主席由陈婧担任, 负责比赛的大纲、技术标准、命题、测评、题目讲解、投诉和举报处理等工作。竞赛办公室设在CCF宁波运营中心, 负责大赛的日常运营工作, 由王晓东担任主任。随后, 秘书长给徐建昌、陈婧等专家颁发了感谢证书。

组织委员会成员王晓东向大会汇报了赛事的组织方案。王晓东指出, CAC不仅要明确赛事目标, 区别于现有的ACM、CCSP等知名竞赛, 避免同质化竞争; 同时引入人工智能、大数据、机器学习等前沿技术, 致力于解决实际问题。

技术委员会主席陈婧向大会汇报了赛事的技术方案。陈婧表示, 命题方向考虑与国家产业、行业关切问题相结合, 同时需面向本科生、研究生和工程师等不同人群, 全方位考察参赛者在算法设计、编程能力、算法速度、程序健壮性、安全性、系统设计等方面的能力。

在大会的交流讨论环节, 各位专家就赛事组织、技术方案、赛区组织、招商财务等方面开展了讨论并确定了赛事的方案框架、组织委员会和技术委员会的工作职责以及建立专业的赛事运营团队。同时, CAC将加强与CCF分部、高校、企业等开展全面合作, 加强赛事的宣传和推广。

据 CCF 微信公众号