

# 基于去噪图自编码器的无监督社交媒体文本摘要\*

贺瑞芳<sup>1,2</sup>, 赵堂龙<sup>1,2</sup>, 刘焕宇<sup>1,2</sup>

<sup>1</sup>(天津大学 智能与计算学部, 天津 300350)

<sup>2</sup>(天津市认知计算与应用重点实验室, 天津 300350)

通信作者: 贺瑞芳, E-mail: [rfhe@tju.edu.cn](mailto:rfhe@tju.edu.cn)



**摘要:** 社交媒体文本摘要旨在为面向特定话题的大规模社交媒体短文本 (称为帖子) 产生简明扼要的摘要描述. 考虑帖子表达内容短小、非正式等特点, 传统方法面临特征稀疏与信息不足的挑战. 近期研究利用帖子间的社交关系学习更好的帖子表示并去除冗余信息, 但其忽略了真实社交媒体情景中存在的不可靠噪声关系, 使得模型会误导帖子的重要性与多样性判断. 因此, 提出一种无监督模型 DSNSum, 其通过去除社交网络中的噪声关系来改善摘要性能. 首先, 对真实社交关系网络中的噪声关系进行了统计验证; 其次, 根据社会学理论设计两个噪声函数, 并构建一种去噪图自编码器 (denoising graph auto-encoder, DGAE), 以降低噪声关系的影响, 并学习融合可信社交关系的帖子表示; 最终, 通过稀疏重构框架选择保持覆盖性、重要性及多样性的帖子构成一定长度的摘要. 在两个真实社交媒体 (Twitter 与新浪微博) 共计 22 个话题上的实验结果证明了所提模型的有效性, 也为后续相关领域的研究提供了新的思路.

**关键词:** 社交媒体文本摘要; 图表示学习; 图神经网络; 去噪自编码器

**中图法分类号:** TP18

中文引用格式: 贺瑞芳, 赵堂龙, 刘焕宇. 基于去噪图自编码器的无监督社交媒体文本摘要. 软件学报. <http://www.jos.org.cn/1000-9825/7199.htm>

英文引用格式: He RF, Zhao TL, Liu HY. Denoising Graph Auto-encoder for Unsupervised Social Media Text Summarization. Ruan Jian Xue Bao/Journal of Software (in Chinese). <http://www.jos.org.cn/1000-9825/7199.htm>

## Denoising Graph Auto-encoder for Unsupervised Social Media Text Summarization

HE Rui-Fang<sup>1,2</sup>, ZHAO Tang-Long<sup>1,2</sup>, LIU Huan-Yu<sup>1,2</sup>

<sup>1</sup>(College of Intelligence and Computing, Tianjin University, Tianjin 300350, China)

<sup>2</sup>(Tianjin Key Laboratory of Cognitive Computing and Application, Tianjin 300350, China)

**Abstract:** Social media text summarization aims to provide concise summaries for large-scale social media short texts (referred to as posts) targeting specific topics. Given the brief and informal contents of posts, traditional methods confront the challenges of sparse features and insufficient information. Recent research endeavors have leveraged social relationships among posts to refine post contents and remove redundant information, but these efforts neglect the presence of unreliable noise relationships in real social media contexts, leading to erroneous assessments of post importance and diversity. Therefore, this study proposes a novel unsupervised model DSNSum, which improves summarization performance by removing noise relationships in the social networks. Firstly, the noise relationships in real social relationship networks are statistically verified. Secondly, two noise functions are designed based on sociological theories, and a denoising graph auto-encoder (DGAE) is constructed to mitigate the influence of noise relationships and cultivate post contents of credible social relationships. Finally, a sparse reconstruction framework is utilized to select posts that maintain coverage, importance, and diversity to form a summary of a certain length. Experimental results on a total of 22 topics from two real social media platforms (Twitter and Sina Weibo) demonstrate the efficacy of the proposed model and provide new insights for subsequent research in related fields.

\* 基金项目: 国家自然科学基金 (62376192, 62376188)

收稿时间: 2023-07-05; 修改时间: 2023-11-22, 2024-02-06; 采用时间: 2024-04-02; jos 在线出版时间: 2024-06-20

**Key words:** social media text summarization; graph representation learning; graph neural network (GNN); denoising auto-encoder (DAE)

## 1 引言

社交媒体文本自动摘要(简称社交媒体摘要)旨在针对特定话题的大规模社交媒体短文本(称为帖子)产生一段简明扼要的摘要描述. 该技术能够有效缓解社交媒体上的信息过载问题, 以帮助用户快速获取有效信息. 已有的摘要方法总体分为两种类型: 抽取式和生成式摘要. 前者主要从输入的原文中识别并抽取重要的、有代表性的语义单元形成摘要, 其间不涉及文本的生成与改写; 后者则是根据输入文档, 由生成模型根据词表生成摘要描述, 该方法需要模型改写或重新组织原文内容来形成最终的摘要.

近年来, 随着如带有注意力机制的序列到序列模型(Seq2Seq)<sup>[1]</sup>、Transformer<sup>[2-4]</sup>、对比学习<sup>[5-7]</sup>以及大规模预训练模型<sup>[8-15]</sup>的出现, 这两种类型的摘要方法在传统长文档领域都取得了长足的发展. 然而, 目前这些方法多数需要大规模的标注数据(如文档-摘要对)对模型进行训练, 而这些训练数据在除新闻领域外的其他领域通常难以构建<sup>[16]</sup>. 在社交媒体领域, 训练语料的构建更加困难<sup>[17]</sup>, 原因在于标注者通常需要阅读关于特定话题的所有帖子, 然后撰写对应的参考摘要, 而帖子的数量通常过于庞大, 阅读所有的帖子会耗费大量的时间成本. 其次, 由于社交媒体上帖子话题的敏感性以及高度的实时性, 对某一个特定话题帖子集合的标注无法泛化到其他话题上, 因此需要对各个不同话题的帖子独立地进行标注任务, 大大提高了数据标注的难度.

由于社交媒体上的文本与传统长文档具有许多不同的特点, 如文本内容较短、表达不规范与多样化、存在大量噪声等, 因此, 尽管摘要技术在传统长文档上取得了较大的进展, 相关的摘要方法在迁移到社交媒体领域时, 经常难以取得满意的效果, 这些挑战严重阻碍了社交媒体领域摘要技术的发展.

已有的社交媒体摘要研究大多将每个帖子看作独立的整体, 并根据每个帖子的文本内容独立地提取特征, 并基于帖子的特征采用基于图排序或者聚类的算法来选择重要性较高的帖子形成摘要<sup>[18-22]</sup>. 然而, (1) 社交媒体上的帖子通常内容较短并且表达不规范, 充满了不正式的表达方式, 例如缩写、省略、同义词、拼写错误以及语法错误等. 如果将每个帖子单独对待, 一个单独的帖子经常包含不完整的信息, 无法提供足够充分的信息来计算其重要性. (2) 社交媒体依靠用户之间的社会交互来完成信息的传播, 用户之间频繁的交互有助于促进社交网络上的信息的传播<sup>[23]</sup>. 因此, 社交媒体上的帖子是嵌入在社交网络中的, 并且大量帖子之间具有潜在的交互关系, 而非相互独立的. 之前的方法对帖子的独立假设导致其忽视了帖子之间的关系信息, 仅考虑帖子的文本内容特征, 导致帖子特征的稀疏性.

一些研究证明了社交媒体上特定的社交信号对于社交媒体上内容的分析具有促进作用<sup>[24-26]</sup>. 因此, 进一步的研究尝试通过引入额外的社交信号(例如帖子的点赞数、转发数、回复数以及用户的粉丝数等)来解决单个帖子信息不足的问题. 进一步, He 等人<sup>[27]</sup>从社会学理论<sup>[28,29]</sup>的角度验证了社交关系对帖子之间内容相关性的影响. 不同于传统文档, 社交网络上的用户通过发布帖子来传播他们的观点, 因此, 社交媒体上的帖子具有天然的交互性, 这也导致了用户之间的交互关系会影响其帖子内容的形成. 他们在真实的社交媒体数据上进行实验, 提出并验证了社交一致性与社交传染性理论, 即具有交互关系的用户在短时间内通常具有更加相似的特征和观点. 并将用户间的社会关系泛化到帖子级别, 构建帖子之间的交互关系网络, 以这种社会学理论指导提升了社交媒体摘要内容选择的性能.

上述借鉴社会学理论的方法为社交媒体文本摘要的发展提供了新的思路和方向, 但是该方法目前仍存在局限性: (1) 真实的社交网络中, 用户之间的交互关系更为复杂. 一个用户通常会与多个用户存在交互关系, 并且不同的交互关系类别具有不同特点. 如图 1 所示, 用户 2 与用户 3 具有交互关系, 关注的内容都是刷新率, 因此发布的内容具有较高的相似性; 同样的, 用户 4 与用户 5 则更加关注摄像头, 其发布的内容也具有较高的相似度; 而用户 1 与用户 4 和用户 2 虽然具有交互关系, 但是这种交互关系更倾向于上下文的关系, 即用户 1 发布的内容是用户 2 与用户 4 的上文, 只有结合用户 1 发布的内容看, 才能了解用户 2 与用户 4 内容的含义. 因此在这种情况下, 用户 1 的内容对于理解用户 2 和用户 4 内容的含义是具有补充作用的. (2) 现实世界中的社交网络往往存在大量的噪声

信息, 即网络中的社会关系可能是不可靠的. 例如, 一方面, 有些用户之间虽然存在社会关系, 但是他们之间的实际交互可能并不频繁, 比如常见的“僵尸粉”; 另一方面, 有些用户之间虽然没有显式的社会关系连接, 但是他们之间也可能共享较多的相似特征, 从而有更大的可能性成为朋友. 这些异常情况使得对于社交网络中关系的应用更加困难.

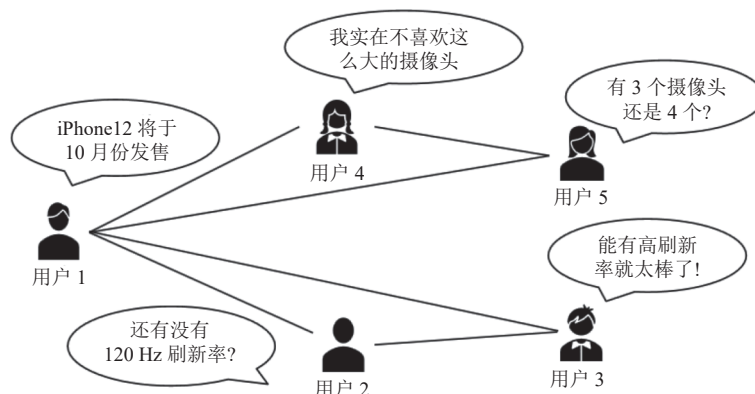


图1 社交媒体网络示例

总体来说, 社交网络上的异常关系可以分为以下两种: (1) 两个具有社交关系的用户可能持有不同的观点, 或者发表不同的内容. (2) 一些没有社交关系的用户也可能具有较为相似的特征或观点. 上述两种情况分别定义为虚假关系与潜在关系. 在利用帖子之间的社交关系时, 这些异常的社会关系使得真实的社会网络结构存在一些不可靠因素, 导致模型引入额外的偏差, 从而降低模型对帖子特征的准确表示. 这些噪声关系对于社会关系的利用会产生较大的负面影响, 因此, 如何识别并去除网络中的这些噪声信号, 是一个亟待解决的研究内容. 同时由于社交媒体环境下的标注数据获取成本高昂, 因此本文中我们致力于研究如何在缺乏标注数据的情况下有效地移除社交网络中的噪声关系, 从而减小噪声关系给摘要带来的影响.

本文提出了一种对噪声关系更加鲁棒的无监督抽取式社交媒体摘要模型 DSNSum (denoising social network for social summarization). 该模型能够在没有任何标注数据的情况下学习移除社交网络中的噪声关系, 并融合帖子的文本内容与可信社交关系来进行抽取式摘要. DSNSum 具有如下特征: (1) 考虑了帖子之间的社交关系来学习社会化的帖子表示; (2) 能够移除社交网络中的噪声关系来提升帖子表示的可信度和准确性, 从而减少噪声关系带来的偏差信息. 首先, 本文构建帖子级别的社交关系网络并利用图注意力网络<sup>[30]</sup>通过从邻居节点聚合相关内容和背景信息来学习信息量更丰富的帖子表示, 这些额外的信息能够帮助缓解单一帖子内容简短导致的信息不足的问题. 其次, 为了使模型对噪声关系更加鲁棒, 本文设计了一个去噪图自编码器模块 (denoising graph auto-encoder, DGAE), DGAE 能够以一种“加噪-去噪”的方式学习移除社交网络中的噪声关系. 具体来说, 通过设计两个噪声函数向原始社交关系网络中添加噪声关系实例, 生成伪社交关系网络, 然后将带有噪声关系的伪社交关系网络与帖子的内容信息作为 DGAE 的输入对其进行编码, 并根据编码得到的潜在表示尝试解码重构回原始的未添加噪声关系的社交关系网络以及帖子的原始文本内容, 从而学习识别与移除网络中噪声关系的能力. 在测试阶段, DGAE 将真实的社交关系网络作为输入, 移除其中的噪声关系并产生可靠的帖子表示. 最终将可靠的帖子表示输入基于稀疏重构框架的摘要抽取器, 选择满足覆盖性、重要性及多样性的帖子组成一定长度的摘要.

本文的主要贡献点如下.

(1) 基于社会学理论, 我们首次形式化地定义了社交网络环境中的两种噪声关系 (即虚假关系与潜在关系), 并通过实验验证了两种噪声关系的存在. 这是对社会学理论的重要补充, 为理解和处理社交网络中的噪声关系提供了新的方法.

(2) 提出了一种对噪声关系更加鲁棒的无监督社交媒体摘要模型 DSNSum. 能够缓解社交关系网络中噪声关

系的影响,并学习可靠的社会化帖子表示,从而改进摘要的覆盖性、重要性与多样性.

(3) 设计了去噪图自编码器模块,能够利用噪声函数自动构造训练数据,从而能够在缺乏标注数据的情况下学习去除网络中的噪声关系,缓减对标注数据的依赖,大大扩展了模型的应用场景.

(4) 在两个真实世界的社交媒体数据上进行了实验验证.定量地分析了真实社交网络中去噪前与去噪后噪声关系的分布情况,验证了去噪模块的有效性.

## 2 相关工作

### 2.1 社交媒体文本摘要

不同于传统文本摘要,由于社交媒体上的文本具有长度短、噪声大、表达非正式化等特点,并且缺乏相应的标准参考摘要.其标准参考摘要的构建需要人工进行标注,成本高昂,目前尚未提出较为有效的自动化构造训练数据的方法,导致社交媒体摘要领域的相关实验数据较为稀少.之前的研究提出了面向社交媒体领域的短文本摘要数据集<sup>[31]</sup>及相关方法<sup>[32-35]</sup>,但其任务目标与本文所要解决的任务并不相同,他们尝试为给定的一条帖子生成更加简短的摘要版本.这种任务与前文所述单文档摘要任务比较类似,实际上是对单个较长的帖子进行摘要,生成一个较短的版本.常用方法也与前文所述传统单文档摘要方法类似,将摘要问题转化为句子分类或者序列标注任务,利用已有的标注数据,即帖子-摘要对,训练一个基于神经网络的摘要模型.本文的任务与这些工作的不同之处在于,针对一个话题相关的帖子集合进行摘要,而不是为单个帖子生成摘要.不同于传统文档,社交媒体上具有更加丰富的数据形式.从利用数据方面来说,现有的社交媒体短文本摘要方法主要经历了3个阶段:基于内容特征的摘要方法,考虑简单社交信号的方法以及融合社会关系的方法.

#### 2.1.1 基于内容特征的社交媒体摘要

对于文本摘要任务来说,最直观的方式就是基于文本内容特征来进行摘要的抽取.该类方法需要首先从原始文本中提取特征,例如句子的长度、关键词、词频、短语等,然后根据文本的特征来判断每个句子的重要程度,从而判断是否适合作为摘要.Chua等人<sup>[36]</sup>尝试利用话题模型与帖子的时序信息,从面向特定事件的推特帖子集合中提取最具代表性的帖子来产生用户感兴趣的摘要.Ganesan等人<sup>[37]</sup>将摘要生成任务建模为一种优化问题,使用一种基于修改的互信息函数来衡量句子的信息度,使用n元语言模型来衡量句子的可读性,并提出了一些启发式算法来求解优化问题.Inouye等人<sup>[38]</sup>提出利用混合TF-IDF(term frequency inverse document frequency)权重来衡量句子的重要性,并选取重要性最高的若干句子作为摘要.Sharifi等人<sup>[39]</sup>则提出一种短语强化算法来寻找包含话题短语的出现频率最高的短语,并根据该短语选择句子来生成最终的摘要.另外,在社交媒体领域,也可以采用基于图排序的方法进行摘要,通过将每个帖子看作一个节点,根据帖子之间内容的相似度来构建节点之间的边,构成一个图结构,然后利用图排序算法(如PageRank)来对图中的节点进行重要性排序,最终选择重要性较高同时冗余度较低的节点作为摘要<sup>[40,41]</sup>.Keswani等人<sup>[42]</sup>最近提出对社交媒体上的内容进行摘要时,应充分考虑来自不同方面用户的声音,提出从方言的角度提升摘要的多样性,在包含不同种族和性别的社会群体使用方言撰写的帖子数据上进行实验,相比于传统的摘要方法取得了更好的多样性.Zogan等人<sup>[20]</sup>则进一步将社交媒体摘要技术应用到社交网络中用户抑郁症检测任务,通过对社交媒体上用户发布的历史帖子内容进行摘要,抽取出其中的主要内容,据其进行抑郁症的检测,也体现了社交媒体摘要技术的广泛应用场景.然而这些方法仅考虑了帖子的文本内容信息,而社交网络中的帖子文本内容经常存在长度较短、噪声大、表达非正式的特点,导致对文本内容的利用更加困难.

#### 2.1.2 考虑简单社交信号的社交媒体摘要

进一步的研究发现,社交媒体平台提供的许多具有社交意义的属性对于识别帖子的流行度以及重要性也具有指导作用.由于社交媒体的交互性,平台通常会提供一些社交信号,如帖子的点赞数、转发数、评论数等.之前的很多研究已经证明了帖子的转发对于识别用户的影响力<sup>[43]</sup>,识别帖子的信息量<sup>[26]</sup>以及分析网络结构<sup>[25]</sup>具有促进作用.Alsaedi等人<sup>[44]</sup>在计算帖子的重要性过程中,不仅考虑帖子的文本内容,同时还考虑了帖子的转发数量,并认为转发数量的多少反映了帖子本身的流行程度.Liu等人<sup>[45]</sup>也提出,社交媒体中单条帖子消息往往难以提供足够

的信息来计算它的重要性, 因此他们在衡量帖子的重要程度时, 同时考虑了帖子的转发数量以及帖子作者的粉丝数量等社会关系相关的特征. 其中, 作者的粉丝数量从一定程度上能够反映作者的社会影响力, 粉丝数量越多, 该作者发布的内容就能够传播给越多的人, 从而具有越大的社会影响力. 关于作者的社会影响力, Duan 等人<sup>[46]</sup>对 Twitter 内容进行摘要时, 同时考虑文本内容、作者的社会影响力以及文本的质量, 并根据这些指标对文本进行排序来选择最终的摘要. Li 等人<sup>[47]</sup>提出, 社交媒体上的用户在转发帖子的同时, 可以附加个人的评论与观点, 这样不仅能进一步传播原始帖子的信息, 同时也扩展了原始帖子的内容. 他们根据帖子之间的转发与回复关系将原始帖子集合构成了树状结构, 并对整棵树进行摘要. 通过使用条件随机场来检测树中的重要节点 (leader) 与普通节点 (follower), 从而区分帖子之间的重要性. 除上述特征以外, 许多其他社交信号例如帖子中的链接和标签以及社交网络中的社团关系等, 也被用来作为辅助特征来促进摘要过程. 例如 Dutta 等人<sup>[48]</sup>提出一种基于图的推特摘要方法, 他们将每条帖子看作一个节点, 并从多个角度衡量节点之间的相似度, 例如单词共现关系、链接 (URL)、标签 (Hashtag)、用户名以及余弦相似度等. 之后在相似度图上进行社团检测来挖掘图中的社团关系信息, 并识别每个社团中的重要推文作为最终的摘要. 这些方法通过引入社交网络中的社交信号特征来学习更加丰富的帖子表示, 此类社交信号对于识别帖子的重要性与流行度具有一定作用, 但是简单的数值信号包含的信息量有限, 并且无法为帖子表示学习提供充足的语义信息, 因此对于帖子表示质量的提升有限. 同时, 这些工作仍然将帖子看作相互独立的个体, 忽略了帖子之间的交互关系, 导致丢失了更加深层次的社交关系特征.

### 2.1.3 融合动态社交关系的社交媒体摘要

已有的研究工作指出, 社交网络中节点的网络结构与节点自身的影响力具有紧密联系<sup>[49]</sup>. 曹玖新等人通过对社交媒体上信息转发与传播特征的研究, 指出社交网络中用户之间的历史交互频率可能会影响用户对于信息的传播行为<sup>[50]</sup>. 因此, 社交网络中的交互关系与网络结构对网络中内容信息的分析同样具有指导意义. 一些研究工作考虑引入社交网络中的社会关系来促进社交媒体摘要. 例如, Chang 等人<sup>[51]</sup>提出, 由于社交媒体上每个帖子的内容都非常短, 缺乏足够丰富的语义信息, 因此仅依靠帖子本身的内容经常难以准确地理解其含义. 同时, 社交媒体上具有丰富的用户交互关系, 因此他们提出利用用户之间的交互关系来构建帖子的上下文语境, 并结合帖子所处的上下文语境进行摘要, 从而强化对于帖子语义的理解. 然而他们仅从用户级别考虑了社交关系信号, 忽略了帖子级别的社会联系, 并且他们将交互关系抽象为简单的特征. He 等人<sup>[27]</sup>则以社会学理论中的表达传染性与表达一致性理论为依据, 构造帖子之间的一阶关系网络, 并将帖子之间的社会关系整合到稀疏重构的框架中, 利用社会关系为帖子内容的重构增加额外的正则项, 从而过滤相关用户产生的冗余内容, 提高摘要的多样性. 之后, He 等人<sup>[52]</sup>又进一步将帖子之间的社会关系扩展到了高阶的情况, 同时将一致性理论泛化到标签共现关系上, 从社会关系与标签共现关系两种角度来过滤冗余信息, 提升摘要的多样性. 进一步他们又将图神经网络引入到对用户之间社交关系的挖掘过程中, 从而改善社交媒体文本表示的质量以提高摘要性能<sup>[53]</sup>. 这些研究试图以社会学理论为依据, 通过挖掘节点之间的社会关系来促进节点表示学习. 但是他们忽略了在真实的社交关系网络中, 经常存在并不可信的噪声关系, 引入这些噪声关系会为节点内容的表示带来额外的偏差, 从而影响节点表示的质量. 本文则通过采用去噪的思想来移除网络中噪声关系带来的影响.

## 2.2 图神经网络

近年来, 图卷积网络 (graph convolutional network, GCN)<sup>[53-56]</sup>由于其出色的性能与较好的可解释性受到越来越多的关注, 它将卷积操作从欧氏空间扩展到图结构的数据中, 从而能够有效捕捉网络的拓扑结构信息. 后续的许多研究在 GCN 的基础上提出了变种方法<sup>[30,57,58]</sup>, 并在众多的下游任务中得了较好的性能. GCN 同样被应用于文档摘要任务. Doan 等人<sup>[54]</sup>构建句子关系图结构, 其中节点表示句子, 节点之间的边用于捕捉句子之间的关系, 并在图上利用 GCN 学习句子节点的表示, 并用于后续的重要性评估. 然而, 他们主要应用于长文档领域, 其中由句子关系形成的图结构与在社交媒体领域中的社交网络关系具有较大的区别. Liu 等人<sup>[53]</sup>在社交关系网络上使用 GCN 来整合文本内容与社交关系特征到统一的表示中, 但是他们没有区分不同邻居之间的重要性, 限制了模型的表达能力. 本文从社交关系的角度重新考虑社交媒体摘要任务, 利用带有注意力机制的图注意力网络来动态捕捉帖子的

社交上下文,从而为帖子提供更丰富的背景信息,缓解帖子信息不足的问题.

### 2.3 加噪与去噪

去噪自编码器 (denoising auto-encoder, DAE) 被广泛应用于众多无监督模型中,用于解决众多下游任务如文本生成<sup>[59,60]</sup>, 句子压缩<sup>[58]</sup>以及观点摘要<sup>[16]</sup>. DAE 先向数据中添加噪声并对带有噪声的数据进行编码,然后再尝试根据编码表示重构原始不带噪声的数据,通过这种“加噪-去噪”的模式训练模型对噪声的鲁棒性. 这种学习模式避免了对训练数据的依赖,因此广泛用于训练数据不足的环境下. 同时,这种训练模式也被应用于预训练模型<sup>[8,9]</sup>. 例如,掩码语言模型<sup>[8]</sup>也可以看作是一种“加噪-去噪”的训练模式,其中的噪声函数即为随机屏蔽掉一些单词. 已有的方法主要采取基于噪声的数据增强策略来构建或扩展训练数据. Amplayo 等人<sup>[16]</sup>以一种启发式的方法向文本中添加噪声并训练模型基于加噪后的数据产生摘要. 然而,在社交媒体领域,噪声不仅仅存在于文本内容中,且同样存在于帖子之间的社交关系中. 因此,如何移除噪声关系对社交媒体文本摘要具有重要意义. 一些研究致力于通过识别网络中重要的节点和边并移除不重要的边来挖掘复杂网络的主要结构(称为 Network Backboning)<sup>[61,62]</sup>. 这些工作主要考虑网络的拓扑结构,并没有考虑网络的属性信息. 本文提出以无监督的方式移除网络中噪声关系的方法. 该方法能够融合可信社交关系特征与文本内容信息来学习鲁棒的帖子表示,从而促进抽取式摘要.

## 3 问题定义

本文主要聚焦面向社交媒体的抽取式摘要任务,即从特定话题的输入帖子集合中,抽出信息量大、冗余度低、最具代表性的  $L$  个帖子形成摘要,其中  $L$  决定了最终输出摘要的长度. 由于摘要任务本身可以看作是一个信息压缩的过程,在压缩过程中必然会有信息的损失,因此该任务的根本目的就是在压缩文本长度的同时,尽可能减少信息的损失,保留更多重要而多样化的信息. 对于本文所研究的抽取式社交媒体摘要任务的形式化定义如下.

给定关于特定话题的原始帖子集合  $\mathcal{S} = \{s_1, s_2, \dots, s_N\}$ , 其中帖子数量为  $N$ ; 用户集合记为  $\mathcal{U} = \{u_1, u_2, \dots, u_M\}$ , 用户数量为  $M$ . 用户、帖子以及它们之间的关系共同构成了一个图结构  $\mathcal{G} = \{\mathcal{V}, \mathcal{E}\}$ . 其中,  $\mathcal{V} = \{\mathcal{V}^s \cup \mathcal{V}^u\}$  表示节点集合,  $\mathcal{V}^s$  表示帖子节点集合,  $\mathcal{V}^u$  表示用户节点集合.  $\mathcal{E} = \{\mathcal{E}^{uu} \cup \mathcal{E}^{us}\}$  表示关系集合, 其中  $\mathcal{E}^{uu} \in \mathbb{R}^{M \times M}$  表示用户-用户之间的社交关系集合,  $\mathcal{E}^{us} \in \mathbb{R}^{M \times N}$  表示用户-帖子之间的发布关系集合. 更具体来说,如果用户  $u_i$  与用户  $u_j$  在社交媒体上具有朋友关系,那么用户节点  $u_i$  与  $u_j$  之间具有一条边,即  $\mathcal{E}_{ij}^{uu} = 1$ , 否则  $\mathcal{E}_{ij}^{uu} = 0$ . 同时,如果帖子  $s_j$  是由用户  $u_i$  发布的,那么用户节点  $u_i$  与帖子节点  $s_j$  之间具有边相连,即  $\mathcal{E}_{ij}^{us} = 1$ , 否则  $\mathcal{E}_{ij}^{us} = 0$ . 给定上述定义,抽取式社交媒体文本摘要任务的目标为:从原始帖子集合  $\mathcal{S}$  中抽取  $L$  ( $L \ll N$ ) 个帖子组成摘要,同时保留原始输入帖子集合中尽可能全面的信息,减小信息损失.

## 4 DSNSum 总体框架

本文提出的 DSNSum 模型整体结构如图 2 所示,共包含 5 个部分:(1) 文本内容编码器;(2) 伪社交关系网络构建;(3) 残差图注意力网络编码器;(4) 双重构解码器;(5) 基于稀疏重构的摘要抽取器. 其中(1)-(4)共同构成去噪图自编码器模块. 由于图中空间有限,对输入输出文本进行了截断,本文输出摘要的基本单元为帖子. 首先构建帖子级别的社交关系网络,并使用图注意力网络对社交关系网络中的帖子节点进行编码表示,图注意力网络能够收集网络中相邻节点的信息,为当前节点提供社交上下文线索,缓解单个帖子信息不足的问题,同时还能够为不同的邻居节点赋予不同的注意力权重,从而在聚合上下文信息时更加关注相关信息,忽略无关信息. 其次,为了使模型对于网络中的噪声关系具有更强的鲁棒性,我们设计了两种噪声函数以及去噪图自编码器结构. 其中,噪声函数通过向原始社交关系网络中添加噪声关系来创建伪社交关系网络,去噪图自编码器则学习识别并去除伪社交关系网络中的噪声,这样以一种先加噪后去噪的模式进行训练,一方面使得模型能够学习识别并移除网络中噪声关系的能力,另一方面又避免了对标注数据的依赖,从而避免了昂贵的数据标注代价. 最终,去噪图自编码器学到融合社交上下文与可信交互关系的帖子表示,并将其输入到基于稀疏重构的摘要抽取器中来抽取最终的摘要.

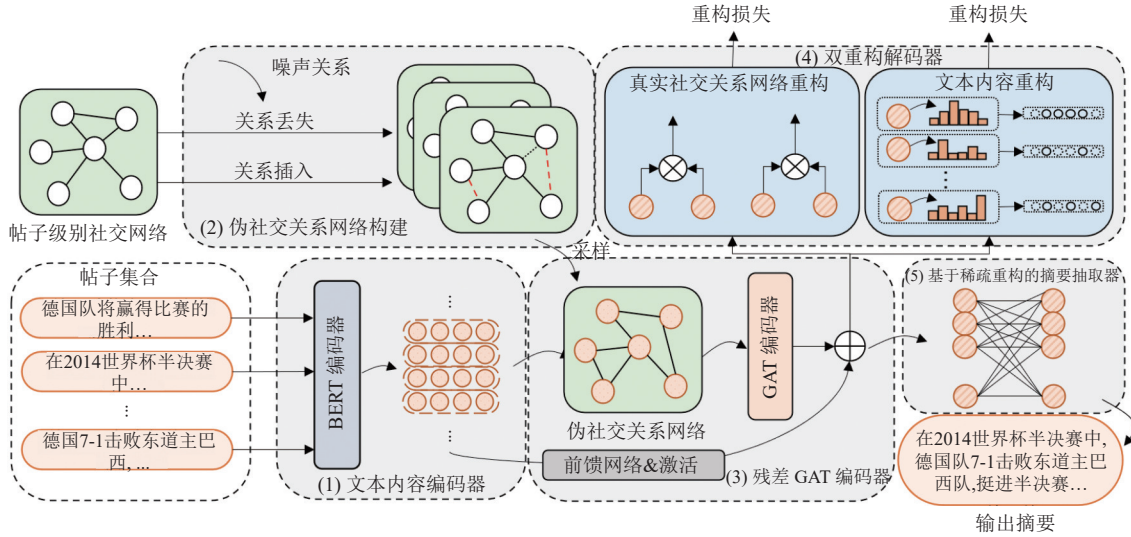


图2 DSNSum 模型整体架构图

### 4.1 社交关系网络构建

由于帖子经常存在内容短小、噪声大等特点, 仅依靠文本内容难以获取足够的信息量. 在社交媒体环境下, 社会学理论和社交网络的拓扑特征已经被证明对许多下游任务有促进作用<sup>[53]</sup>. 例如, 相关研究<sup>[25,63]</sup>验证了社交一致性理论在社交媒体数据中的存在, 该理论指出, 同一个用户在短时间内针对特定的话题通常保持一致的观点或看法. 社交传染性理论指出, 许多社会行为以及情感<sup>[64]</sup>等会沿着社交网络进行传播. 受这些社会学理论的启发, 本文提出一种简单的建模帖子间社会关系的方法, 并同时考虑了社交一致性与社交传染性两种社会学理论. 形式化地, 构建帖子级别社交关系网络  $\hat{\mathcal{G}} = (\hat{\mathcal{V}}, \hat{\mathcal{E}})$ , 其中包含了节点集合  $\hat{\mathcal{V}}$  与边集合  $\hat{\mathcal{E}}$ , 每个节点表示一个帖子, 每条边表示帖子之间的社交关系, 构建方法如下: 对于一个用户  $u_i$ , 令  $\mathcal{N}(u_i) = \{u_k | \mathcal{E}_{ik}^{us} = 1\}$  表示用户  $u_i$  的邻居集合, 令  $\mathcal{P}(u_i) = \{s_k | \mathcal{E}_{ik}^{us} = 1\}$  表示由用户  $u_i$  发布的帖子集合. 基于上述定义, 按照如下两个准则构建帖子级别的社交关系网络:

社交一致性: 如果帖子  $s_i \in \mathcal{P}(u_k)$ , 且  $s_j \in \mathcal{P}(u_k)$ , 则为帖子节点  $s_i$  与  $s_j$  之间构建一条边. 也就是说, 由同一个用户发布的帖子之间建立一条边. 该关系反映了社交一致性关系<sup>[29,30]</sup>.

社交传染性: 如果  $s_i \in \mathcal{P}(u_i)$ ,  $s_j \in \mathcal{P}(u_j)$ , 并且  $u_i \in \mathcal{N}(u_j)$  或  $u_j \in \mathcal{N}(u_i)$ , 则为帖子节点  $s_i$  与  $s_j$  之间建立一条边. 也就是说, 允许由具有朋友关系的用户发布的帖子之间进行交互. 该类关系反映了社交传染性关系<sup>[25,63]</sup>.

根据上述规则, 可以构建出帖子级别社交关系网络, 其拓扑结构可以用邻接矩阵  $\mathbf{A} \in \mathbb{R}^{N \times N}$  来表示, 该网络只包含帖子节点和他们之间的社交关系. 帖子之间的关系允许帖子之间进行信息传播, 从而能够捕捉帖子的社交上下文信息, 缓解单个帖子信息不足的问题.

### 4.2 噪声观察

之前的研究工作验证了社交理论在社交媒体上的存在, 并将其总结为表达一致性<sup>[28]</sup>与表达传染性<sup>[29,65]</sup>. 他们假设具有社交关系相连的帖子更加倾向于具有相似的内容和观点. 然而, 真实世界中的社交网络经常包含不可靠的社交关系, 本文将这些不符合社会学理论假设的关系称为噪声关系. 根据对真实数据的分析与观察, 我们将噪声关系分为两类.

- 虚假关系: 两个用户之间具有社交关系相连, 但是他们发布帖子的内容具有较低的相关性.
- 潜在关系: 两个用户之间没有社交关系, 但是他们发布帖子的内容具有较高的相关性.

由于这种用户之间真实关系的标准数据难以获得, 准确地衡量这两种噪声关系在社交网络中的数量是比较困

难的. 为了探究真实社交网络中噪声关系的分布情况, 并判断是否有必要对社交网络进行去噪, 本文提出一种粗略估计社交网络中噪声关系的方法. 通常来说, 具有社交关系但是内容上相关性较低的帖子之间的关系被视为虚假关系; 没有社交关系但是内容上具有较高相关性的帖子之间被视为具有潜在关系. 因此, 本文通过检测帖子之间社交关系与内容相似性的一致性来判断帖子之间的关系是否是噪声关系. 形式化地, 帖子之间的社交关系矩阵为  $\hat{E} \in \mathbb{R}^{N \times N}$ , 其中  $\hat{E}_{ij} = 1$  表示帖子  $s_i$  与  $s_j$  之间具有社交关系, 否则  $\hat{E}_{ij} = 0$ . 对于网络中的每一对帖子节点  $(s_i, s_j)$ , 如果它们之间具有社交关系, 但是二者的内容相似度  $\Phi_{ij}$  小于阈值  $\theta$ , 则将它们之间的关系视为虚假关系; 同时, 如果它们之间没有社交关系, 但是二者的内容相似度高于阈值  $\theta$ , 则认为它们之间存在潜在关系. 在本文的实验中, 使用 BERT 对帖子进行编码, 得到帖子的内容表示, 并且使用帖子内容表示之间的余弦相似度来衡量帖子内容之间的相似度. 这是一种简单且较为直接的估计网络中噪声关系的方法. 然而, 阈值  $\theta$  的取值会严重影响网络中噪声关系的分布, 因此一个重要的问题是如何确定阈值  $\theta$  的取值.

为了确定噪声关系判断的阈值, 本研究采用了一种基于统计分析的方法. 通过分析真实社交媒体数据, 我们计算了帖子之间内容相似度的分布, 并选择了这个分布的平均值作为阈值. 这个平均值被认为能够代表大多数情况下帖子间关系的一般特性. 为了验证这一阈值的有效性, 我们在多个数据集上进行了实验. 实验结果显示, 使用这个阈值可以有效识别出虚假关系和潜在关系.

$$\theta = \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N \Phi_{ij} \quad (1)$$

其中,  $\Phi_{ij}$  是帖子  $s_i$  与  $s_j$  之间的内容相似度. 需要注意的是, 由于用户间的社交关系较为复杂, 具有社交关系的用户并不一定导致相似的内容, 很多情况下用户之间会具有一些其他的交互关系, 例如具有社交关系的用户之间发布的内容可能会具有上下文的相关关系, 而这种关系无法采用文本内容的相似度来衡量. 此处只为宏观了解噪声关系在社交网络中的分布情况, 对社交关系的类别进行了简化, 仅考虑内容相似性来判断社交关系的真实性.

在两个真实社交媒体数据集 TWEETSUM<sup>[63]</sup>和 Weibo<sup>[47]</sup>上进行了实验(数据集的详细讨论见第 5.1 节), 噪声关系的统计结果如表 1 所示. 结果展示了每个数据集下所有社交网络中噪声关系的平均占比情况(包括虚假关系与潜在关系). 其中, 虚假关系率指的是在所有具有社交关系的节点对中, 虚假关系的占比, 潜在关系率是指在没有社交关系的节点对中, 实际上具有潜在关系的节点对的占比; 平均噪声率则是所有噪声关系的数量(包括虚假关系与潜在关系)与总的节点对个数的比值, 该值反映了网络中噪声关系的占比情况. 根据结果可以看到, 在社交网络中噪声关系普遍存在, 从而验证了对社交网络进行去噪的必要性. 需要注意的是, 一些研究工作(network backboning)尝试移除网络中不重要的边(虚假关系), 但是他们无法处理网络中的潜在关系. 本文提出去噪图自编码器来同时解决网络中的虚假关系和潜在关系.

表 1 两个数据集中原始社交关系网络中的噪声关系分布 (%)

数据集	虚假关系率	潜在关系率	平均噪声率
TWEETSUM	38.61	55.79	55.37
Weibo	83.17	52.66	52.67

### 4.3 去噪图自编码器

对于构建好的帖子级别的社交关系网络, 由于网络中普遍存在噪声关系, 直接使用该网络将会引入严重的噪声偏差. 此外, 考虑用户之间的标准关系标签难以获得, 去除网络中的噪声关系实际上是一个非常困难的任务. 受启发于图自编码器<sup>[57]</sup>和去噪自编码器<sup>[66,67]</sup>, 本文提出一个去噪图自编码器(denoising graph auto-encoder, DGAE), 学习在没有标准标注数据情况下去除社交网络中的噪声关系. 具体来说, DGAE 首先根据噪声函数向输入的网络中添加噪声关系实例, 生成伪社交关系网络. 然后图注意力编码器将采样得到的伪社交关系网络与帖子的内容特征进行编码, 得到帖子节点的隐表示. 为了同时捕捉帖子的社交拓扑结构特征与文本内容特征, DGAE 的解码器尝试基于隐表示同时重构原始的社交关系网络结构与文本内容.



#### 4.3.1 文本内容编码器

对于每个帖子  $s_j \in S$ , 其中  $s_j = [w_1, w_2, \dots, w_t]$ ,  $t$  是帖子中单词的个数,  $w_k$  是帖子  $s_j$  中的第  $k$  个单词. 通过利用预训练的 BERT 模型对帖子进行编码, 得到帖子的向量表示, 如公式 (2) 所示:

$$\mathbf{x}_j = \text{BERT}(s_j) \quad (2)$$

由于社交媒体中的帖子与传统长文档具有许多不同的特征, 如内容较短、表达非正式等, 为了能够更好地适应社交媒体短文本的特点, 对于英文数据, 本文将普通 BERT 模型替换为 BERTweet 模型<sup>[68]</sup>. 对中文数据则采用 BERT-base-Chinese 模型. BERTweet 与 BERT 具有相同的结构, 但是 BERTweet 是在大规模 Tweet 语料上预训练得到的, 因此能够更好地适应社交媒体文本的特点.

#### 4.3.2 基于噪声函数的伪社交关系网络生成

之前的研究假设具有社交关系的帖子之间倾向于具有相似的内容<sup>[27,63]</sup>, 然而噪声关系会严重影响该假设的正确性. 由于缺乏帖子之间真实社交关系的标准标注数据, 为了使模型能够识别噪声关系, 本文根据噪声函数向输入网络中添加噪声关系实例, 自动构建伪训练数据. 具体来说, 两种噪声函数的设计如下.

- 对于网络中每一对未连接的节点, 以概率  $p_i$  为他们建立一条边, 将其连接. 该函数称为关系插入.
- 对于网络中的每条边, 以概率  $p_d$  将他们之间的边移除. 该函数称为关系丢失.

这两种噪声函数分别对应虚假关系和潜在关系. 换句话说, 模型根据噪声函数向输入的社交关系网络中添加这两种噪声函数的实例, 并训练模型识别并进一步移除这些噪声关系.

对于社交网络中未连接的节点对, 由“关系插入”操作建立新边, 定义为离散型随机变量  $y_1$ ; 对已连接的节点对, 由“关系丢失”操作删除边, 定义为离散型随机变量  $y_2$ . 社交网络关系由若干个节点连接而成, 每对节点之间只有连接和非连接状态, 分别对应着 0, 1 这两种离散状态. 因此, 假设随机变量  $y_1$  服从参数为  $p_i$  的伯努利分布, 使得每一对未连接的节点, 以概率  $p_i$  建立一条新边; 随机变量  $y_2$  服从参数为  $p_d$  的伯努利分布, 对于网络中的每条边, 以概率  $p_d$  将之移除. 形式化如下:

对应插入边操作的潜在关系噪声分布为:

$$y_1 \sim B(1, p_i) \quad (3)$$

对应删除边操作的虚假关系噪声分布为:

$$y_2 \sim B(1, p_d) \quad (4)$$

具体来说, 假设原始网络  $\mathcal{G}$  是可靠的, 并构造合成训练数据  $\mathbb{D} = \{(\tilde{\mathcal{G}}, \mathcal{G})\}$ . 本文构建了伪社交关系网络  $\tilde{\mathcal{G}}$ , 同时考虑了在添加噪声之前的真实社交关系网络  $\mathcal{G}$ , 这两个网络共同构成了我们研究的网络结构. 在训练阶段, 模型将伪社交关系网络  $\tilde{\mathcal{G}}$  作为输入, 学习去除噪声关系并重构原始社交关系网络  $\mathcal{G}$ . 在测试阶段, 模型将原始社交关系网络  $\mathcal{G}$  作为输入, 将其视为带有噪声关系的版本, 并尝试去除网络中的噪声关系. 另外, 由于两种噪声关系的比例与优先级也会影响模型的性能, 本文将在第 6.4 节讨论.

#### 4.3.3 残差图注意力网络编码器

到目前为止, 已经得到了伪社交关系网络与帖子的文本内容表示. 为了建模相关帖子之间的交互, 本文采用图注意力网络 (graph attention network, GAT) 作为编码器来整合帖子的社交关系特征与文本内容特征. GAT 可以看作一个信息传播模型, 它通过聚合邻居节点的相关信息来学习节点的特征表示. 同时, 相比于传统的图卷积网络 (graph convolutional network, GCN), GAT 可以为相同邻域内的不同邻居节点赋予不同的权重, 因此能够为重要的节点赋予较高的权重, 并为重要性较低的节点赋予较低的权重, 从而更加动态地聚合社交上下文中的相关信息.

形式化来说, GAT 编码器将节点的特征  $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_N] \in \mathbb{R}^{N \times D}$  与帖子级别社交关系网络结构  $\mathbf{A} \in \mathbb{R}^{N \times N}$  作为输入, 其中  $D$  是节点特征的维度,  $N$  是节点个数. 传播规则如下:

$$\mathbf{H}^{(l+1)} = \sigma(\tilde{\mathbf{A}}\mathbf{H}^{(l)}\mathbf{W}^{(l)} + \mathbf{b}^{(l)}) \quad (5)$$

$$\check{\mathbf{A}}_{ij} = \alpha_{ij}^{(l)} \cdot \mathbf{A}_{ij} \quad (6)$$

其中,  $\mathbf{H}^{(l)}$  是第  $l$  层的输出.  $\mathbf{A}$  是增加了自连接之后的邻接矩阵.  $\alpha_{ij}^{(l)}$  是节点  $i$  与节点  $j$  在第  $l$  层的注意力权重.  $\mathbf{W}^{(l)}$  和  $\mathbf{b}^{(l)}$  是 GAT 第  $l$  层的学习参数. 为了进一步融合帖子的内容特征, 将第 4.3.1 节得到的帖子内容特征作为社交关系网络中帖子节点的初始化表示, 即令  $\mathbf{H}^{(0)} = \mathbf{X}$ . 本文中的注意力计算过程采用缩放点积注意力, 在实现过程中, 还可以将潜在表示  $\mathbf{h}_i$  映射到  $K$  个不同的子空间中, 并在每个子空间中分别计算注意力权重, 从而将普通注意力机制扩展为多头注意力机制:

$$e_{ij}^{head_k} = \frac{((\mathbf{W}_a^{head_k} \mathbf{h}_i)^T \cdot \mathbf{W}_b^{head_k} \mathbf{h}_j)}{\sqrt{D_h}} \quad (7)$$

$$\alpha_{ij}^{head_k} = \frac{\exp(e_{ij}^{head_k})}{\sum_q \exp(e_{ij}^{head_q})} \quad (8)$$

其中,  $D_h$  是注意力机制中的隐层向量维度. 由于对模型每一层中的计算过程均相同, 为了描述简便, 此处忽略了表示层数的上标 ( $l$ ), 并使用上标  $head_k$  来表示第  $k$  个注意力头中对应的参数值.  $\mathbf{W}_a^{head_k} \in \mathbb{R}^{D_h \times D}$  与  $\mathbf{W}_b^{head_k} \in \mathbb{R}^{D_h \times D}$  是第  $k$  个注意力头中的学习参数. 通过这种方式可以得到  $K$  组注意力权重. 由于不同的注意力头从不同的角度捕捉节点之间的关系, 两个节点之间在不同的注意力头中的关系重要性可能会有较大差异. 因此, 本文没有对所有注意力头的结果进行拼接操作, 而是采用了最大化池化操作, 从各个注意力头中选出两个节点之间最强的关系, 作为这两个节点之间的真实关系, 从而将  $K$  组不同的注意力权重统一为最终的注意力得分:

$$\alpha_{ij} = \max(\alpha_{ij}^{head_1}, \alpha_{ij}^{head_2}, \dots, \alpha_{ij}^{head_k}) \quad (9)$$

另一个问题是, 由于社交关系网络的规模取决于网络中的节点个数, 不同的社交关系网络中节点个数可能差距较大, 导致社交关系网络的规模具有较大差异. 同时, 普通的 GAT 容易存在过平滑的问题, 尤其是在网络的规模较小并且网络比较稠密的情况下, GAT 的过平滑问题更为严重, 导致网络中各个节点之间缺乏区分度. 为了缓解 GAT 的过平滑问题, 本文将图注意力网络中的连接层替换为残差连接层, 使得模型能够直接从输入数据中获取信息. 因此, 改进后的残差图注意力网络的传播规则如下:

$$\mathbf{H}^{(l+1)} = f(\mathbf{H}^{(l)}) + \sigma(\check{\mathbf{A}}\mathbf{H}^{(l)}\mathbf{W}^{(l)} + \mathbf{b}^{(l)}) \quad (10)$$

其中,  $f(\cdot)$  是映射函数, 负责将节点特征映射到统一的空间中, 具体实现中使用带有激活函数的全连接层实现.  $\sigma(\cdot)$  表示非线性激活函数. GAT 编码器的深度记为  $L$ , 决定了社交关系网络中信息传播的距离. 最后一层的输出  $\mathbf{H}^{(L)}$  作为 GAT 编码器最终的编码结果, 将用于后续的摘要抽取过程. 为了避免没有社交关系的帖子之间进行相互的信息流动, 本文中将 GAT 的深度设置为 1.

#### 4.3.4 双重构解码器

由于希望编码得到的帖子表示能够同时捕捉帖子的文本内容信息与社交结构信息, 本文设计了双重构解码器, 根据帖子的编码表示同时重构原始的帖子文本内容与帖子之间的社交关系网络拓扑结构.

对于社交关系网络的重构, 我们使用一个关系解码器来预测给定的两个帖子节点之间的社交关系. 解码器根据两个帖子的编码表示的内积来判断他们之间的社交关系情况:

$$p(\hat{\mathbf{A}}_{ij} = 1 | \mathbf{h}_i, \mathbf{h}_j) = \sigma(\mathbf{h}_i^T \mathbf{h}_j) \quad (11)$$

具体来说, 对于图中的每一对节点, 解码器预测他们之间存在社交关系连接的概率, 预测结果记为  $\hat{\mathbf{A}}$ , 其中  $\hat{\mathbf{A}}_{ij}$  表示帖子节点  $s_i$  与  $s_j$  之间存在社交关系的概率.

对于文本内容的重构, 本文提出通过预测帖子与单词之间的关系来保留帖子的文本内容信息. 由于每个帖子通常包含多个单词, 因此内容重构过程建模为一个多标签分类问题:

$$\hat{\mathbf{s}}_i = \sigma(\mathbf{W}_d \mathbf{h}_i + \mathbf{b}_d) \quad (12)$$

其中,  $\mathbf{W}_d \in \mathbb{R}^{V \times Z}$ ,  $\mathbf{b}_d \in \mathbb{R}^V$  是学习参数,  $V$  表示词表大小.  $\hat{\mathbf{s}}_i \in \mathbb{R}^V$  是预测结果,  $\hat{s}_{ij}$  表示帖子  $s_i$  包含单词  $w_j$  的概率.

需要注意的是, 由于原始帖子中存在较多的噪声内容与不规范表达, 在重构的过程中忽略了无意义与噪声的内容(如停用词、拼写错误的单词、缩写、链接等), 这样能够保持一个较小的词表大小. 采用这种重构方式, 一方面能够保持解码器部分的参数量尽可能少, 另一方面能够限制内容解码器的能力, 从而将重构的压力更多地聚焦于主体的编码部分. 由于我们的主要训练目标是训练一个能力较强的编码器, 而非重构模块. 因此, 实验中对文本重构模块采用了较为简单的设计, 从而将文本重构的压力聚集到主体的编码器模块, 尽可能提升编码器的编码能力.

因此, DSNSum 的训练目标包括两部分. 第 1 部分是重构原始社交关系网络结构的损失, 计算解码器的输出结果与真实的社交关系结构之间的二元交叉熵损失:

$$L_g = -\frac{1}{N} \sum_i \sum_j^N (\mathbf{A}_{ij} \cdot \log(\hat{\mathbf{A}}_{ij}) + (1 - \mathbf{A}_{ij}) \cdot \log(1 - \hat{\mathbf{A}}_{ij})) \quad (13)$$

其中,  $\mathbf{A}$  是第 4.1 节构建的原始社交关系网络的邻接矩阵,  $\hat{\mathbf{A}}$  是解码器重构的社交关系网络的邻接矩阵. 文本内容重构损失采用模型预测结果  $\hat{\mathbf{s}}_i$  与真实结果  $\mathbf{s}_i$  之间的二元交叉熵损失:

$$L_c = -\frac{1}{N} \sum_i \sum_j^N (\mathbf{s}_{ij} \cdot \log(\hat{\mathbf{s}}_{ij}) + (1 - \mathbf{s}_{ij}) \cdot \log(1 - \hat{\mathbf{s}}_{ij})) \quad (14)$$

最终的目标函数为两部分损失的加权和, 两部分的权重由参数  $\lambda$  平衡:

$$L = \lambda L_g + (1 - \lambda) L_c \quad (15)$$

#### 4.4 基于稀疏重构的摘要抽取器

为了使产生的摘要能够尽量覆盖到原始帖子集合的主要内容, 本文抽取重要性最大、代表性最高、能够最完整地重构原始帖子集合内容与原始社交关系网络结构的帖子作为最终的摘要. 形式化地, 给定去噪图自编码器编码得到的帖子表示  $\mathbf{H} = [\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_N]$ , 帖子的抽取过程建模为如下的稀疏重构过程:

$$\begin{aligned} \min_{\mathbf{W}} & \|\mathbf{H} - \mathbf{W}\mathbf{H}\| + \beta \|\mathbf{W}\|_{2,1} + \gamma \|\nabla \circ \mathbf{W}\| \\ \text{s.t. } & \mathbf{W} \geq 0, \text{diag}(\mathbf{W}) = 0 \end{aligned} \quad (16)$$

其中,  $\|\cdot\|$  表示 Frobenius 范数,  $\mathbf{W}$  是可学习的权重矩阵,  $\mathbf{W}_{ij}$  表示帖子  $s_i$  对重构帖子  $s_j$  的贡献程度. 为了避免两个或多个帖子同时重构相同的内容, 造成摘要的冗余, 本文设计了一个相似度矩阵  $\nabla \in \mathbb{R}^{N \times N}$  来移除冗余信息, 如果帖子  $s_i$  与  $s_j$  的内容相似度高于阈值  $\eta$ , 则令  $\nabla_{ij} = 1$ , 否则  $\nabla_{ij} = 0$ .  $\circ$  表示哈达玛积操作. 为了避免帖子重构自身, 在重构过程中限制重构系数矩阵的对角元素为 0.  $\beta$  与  $\gamma$  分别为控制对应正则项权重的参数. 同时, 对重构系数矩阵  $\mathbf{W}$  增加 L21 范数约束如下:

$$\|\mathbf{W}\|_{2,1} = \sum_{i=1}^N \sqrt{\sum_{j=1}^N |\mathbf{W}_{ji}|^2} \quad (17)$$

L21 约束会使得每一行中大部分元素为 0, 意味着每个帖子只能由少数若干帖子进行重构, 从而限制摘要的长度. 最终, 每个帖子对于重构所有其他帖子的重要性之和作为帖子的最终得分:

$$\text{score}(s_i) = \sum_{j=1}^N \mathbf{W}_{ji} \quad (18)$$

根据帖子的得分对帖子进行排序, 并迭代地选取得分最高的帖子加入候选摘要集合, 直到达到摘要的长度限制. 由于 DGAE 编码得到的帖子表示同时包含了帖子的文本内容与社交关系网络结构信息, 因此重构过程能够同时从文本内容与社交关系两个角度识别帖子的重要性, 从而提升摘要的覆盖性、重要性与多样性.

## 5 实验设置

### 5.1 数据集与评估标准

本文在两个真实社交媒体数据集上对模型进行验证: TWEETSUM<sup>[63]</sup>与 Weibo<sup>[47]</sup>, 它们分别为英文与中文数据集, 相应的数据统计结果如表 2 所示.

两个数据集中的用户信息均已进行匿名化处理, 每个帖子对应一个随机生成的唯一 ID. TWEETSUM 是一个

面向话题的社交媒体摘要数据集, 其中的帖子均来自 Twitter. 考虑到帖子的实时性, 数据集中帖子的发布时间都分布于相关事件发生前后特定的一段时间间隔内. TWEETSUM 包含共 44 034 个帖子与共计 11 240 个用户, 以及用户之间的社交关系. 每一组帖子集合具有 4 个由标注者提取的标准参考摘要, 用于对抽取摘要结果进行评估. 在本文的实验中, 链接以及其他特殊符号均被移除, 同时对帖子的文本内容进行了词干提取, 并去除停用词, 最终过滤掉长度小于 3 的帖子. Weibo 数据集中的帖子来自新浪微博社交媒体平台, 该数据集中包含 130k 帖子以及 126k 用户, 共分为 10 个热点话题. 其中的帖子根据帖子之间的社交关系以树状结构组织. 每个话题下具有 3 个由标注者构造的标准参考摘要, 用于对摘要结果的质量进行评估. 在实验中使用人们常用的 ROUGE<sup>[69]</sup>评估标准对摘要结果进行评估. 该方法通过对比模型产生摘要与标准参考摘要之间  $n$ -gram 的重合度来评估生成摘要的质量. 本文实验中汇报 ROUGE-1, 2, L 以及 ROUGE-SU\*这 4 个评估标准, 在后文中分别记为 R-1, R-2, R-L 以及 R-SU\*.

表 2 TWEETSUM 与 Weibo 数据集特征统计

统计特征	TWEETSUM	Weibo
话题数	12	10
每个话题下平均帖子数	3 669.50	5 636.20
平均帖子长度	16.24 (单词)	27.33 (字)
每个话题下平均用户数	1 144.25	5 450.80
每个话题下平均词表大小	3 760.08	3 228.10
参考摘要平均长度	453.79 (单词)	424.90 (字)

## 5.2 实现设置

本节将 TWEETSUM 数据的目标摘要长度设定为 25 条帖子, 对 Weibo 中每个话题的目标摘要长度设定为 400 个单词. 对于英文的 TWEETSUM 数据, 采用在大规模推特数据上预训练的 BERTweet 模型<sup>[68]</sup>作为初始内容编码器, 对于中文的 Weibo 数据, 则使用预训练的中文 BERT 模型<sup>[8]</sup>来获取帖子的初始语义表示. 对于两个数据集的帖子表示维度都与 BERT 模型的隐层表示维度保持一致, 设置为 768. 对于模型编码器部分采用 ReLU 激活函数, 解码器部分的激活函数则采用 Sigmoid 函数对结果进行归一化, 从而实现分类. 对于去噪模块, 对两种噪声函数进行了讨论与分析, 实验过程及结果见第 6.4 节. 由于不同社交网络中噪声的分布情况并不一致, 因此根据实验结果与分析, 本文最终将 TWEETSUM 中噪声函数中的两种噪声概率  $p_i$  与  $p_d$  分别设置为 0.4 与 0.1, 将 Weibo 中两种噪声概率均设置为 0.3. 另外, 本文中图注意力网络的头数设置为 4, 并尝试了不同深度的图注意力网络的效果, 最终将图注意力网络深度设置为 1, 即仅聚合直接相连的帖子时效果最好. 这说明帖子的直接邻居节点之间共享较高的内容相关性, 而当聚合范围变大时, 模型会聚合到更多的不相关内容, 从而影响对帖子内容的理解. 最终的损失函数中的平衡因子  $\lambda$  设置为 0.8. 在训练阶段, 采用 Adam 优化器并且将初始学习率设置为 0.01, 学习率随着训练过程的进行逐渐减小. 在摘要抽取阶段, 固定  $\beta = \gamma = 1$ , 并且根据对数据的观察将  $\eta$  设置为 1. 整个模型在单个 NVIDIA TITAN Xp GPU 上进行训练.

## 5.3 对比方法

由于本文提出的方法属于无监督抽取式摘要模型, 因此这里主要选取相同类型的对比模型进行比较. 首先通过对每个话题下不同标准参考摘要之间进行互评来衡量标准参考摘要之间的一致性, 记为 Expert. 为了估算抽取式摘要方法在对应数据集上的性能上限, 提出了 Oracle 方法, 该方法在摘要的抽取过程中能够直接访问标准参考摘要, 并贪婪地选择具有最高 ROUGE-1 得分的帖子加入候选摘要, 直至达到摘要的长度限制. 同时, 设计了 Random 方法, 每次从原始帖子集合中随机选择帖子加入候选摘要集合, 直至达到长度限制, 该方法用来估计抽取式摘要方法在对应数据集上的性能下限.

对于其它对比方法, 本文对比两种类型的模型. 第 1 种仅考虑帖子的文本内容信息, 这些方法包括:

- Centroid<sup>[70]</sup>使用基于中心度的特征来识别与整个文档集合高度相关的句子, 并将其加入候选摘要集合.
- LSA<sup>[71]</sup>使用 SVD 技术来分解原始语料的特征矩阵, 根据奇异值的大小衡量帖子的重要性, 选择奇异值较高

的帖子加入候选摘要集合.

- LexRank<sup>[72]</sup>根据帖子之间的相似度构建相似度图,并在图上利用类似 PageRank 的图排序算法对节点按照重要性排序,并迭代地抽取重要性最高的帖子加入候选摘要集合,直至达到长度限制.

- DSDR<sup>[73]</sup>使用基于线性重构的方法,通过最小化重构损失寻找最优的帖子子集作为摘要.

- MDS-Sparse<sup>[74]</sup>利用稀疏编码技术,通过重构原始语料来识别帖子的重要性,并抽取重要帖子作为摘要.

- PacSum<sup>[75]</sup>是一种改进的基于图的抽取式摘要方法,利用 BERT 对文本进行特征提取,并同时将文档中句子之间的相对位置建模为图中边的方向,从而考虑了图中节点之间的方向性,并根据节点的中心度得分抽取重要帖子加入候选摘要集合.

- Spectral<sup>[76]</sup>是一种无监督多文档摘要方法.它使用基于谱的假设,定义了谱重要性 (spectral impact) 的概念,通过计算每个句子的谱重要性,抽取重要性较高的帖子作为摘要.

- MTGNN<sup>[54]</sup>使用文档中更细粒度的语义单元来捕捉单词和帖子之间的复杂关系,构建了用于产生摘要的异构图神经网络.

第 2 种方法额外考虑了帖子之间的社交网络结构信息,利用网络的拓扑结构来提升摘要的性能,具体包括:

- SNSR<sup>[27]</sup>将社交网络中的社会关系以正则项的方式融合到稀疏重构的框架中,从而去除用户间的冗余信息,抽取更加多样性的帖子作为摘要.

- SCMGR<sup>[53]</sup>在原始社交网络中使用图卷积网络来提取社会化的帖子表示,并使用稀疏重构框架来抽取摘要帖子.但是该方法忽略了网络中噪声关系的影响.

## 6 实验结果分析

### 6.1 主体实验结果

表 3 与表 4 分别展示了本文的 DSNSum 模型和其他对比模型在 TWEETSUM 与 Weibo 数据上的摘要性能.第 1 部分包含了 Expert, Oracle 和 Random 这 3 种基线方法,分别代表不同标准参考摘要之间的一致性、性能上限和性能下限.第 2 部分展示了仅考虑文本内容的摘要方法的评估结果,最后一部分展示了融合社交关系的摘要方法的性能得分.从表 3 与表 4 中的结果可以得到以下观察.

表 3 模型以及对比方法在 TWEETSUM 上的

ROUGE 评估结果

模型	R-1	R-2	R-L	R-SU*
Oracle	58.229	34.902	56.688	29.940
Expert	47.384	15.972	45.111	21.047
Random	41.480	9.6710	39.149	16.408
Centroid	38.172	12.442	36.430	15.409
LSA	43.524	13.077	41.347	18.197
LexRank	42.132	13.302	39.965	18.192
DSDR	43.335	13.106	41.055	17.264
MDS-Sparse	42.119	10.059	40.101	16.686
PacSum	42.603	13.021	40.375	17.268
Spectral	43.488	11.980	41.229	17.794
MTGNN	44.852	12.481	42.102	20.013
SNSR	44.886	13.891	42.800	19.990
SCMGR	45.829	14.081	43.433	20.141
DSNSum (本文模型)	<b>46.506</b>	<b>14.285</b>	<b>44.157</b>	<b>20.757</b>

表 4 模型以及对比方法在 Weibo 上的

ROUGE 评估结果

模型	R-1	R-2	R-L	R-SU*
Oracle	42.024	18.577	18.409	16.511
Expert	47.139	25.289	28.535	20.556
Random	32.880	7.8740	12.504	10.483
Centroid	29.712	7.9580	13.718	9.7410
LSA	29.181	8.3750	12.717	8.9020
LexRank	34.802	8.1000	12.762	11.593
DSDR	19.771	5.3620	8.6790	4.5880
MDS-Sparse	33.019	7.5620	12.599	10.621
PacSum	32.664	8.7600	13.554	10.811
Spectral	33.862	8.6570	12.842	11.260
MTGNN	33.762	8.219	13.558	11.519
SNSR	34.009	7.6220	12.566	10.925
SCMGR	36.405	10.495	<b>14.469</b>	12.722
DSNSum (本文模型)	<b>37.014</b>	<b>10.975</b>	14.224	<b>13.060</b>

(1) 本文的 DSNSum 模型在 TWEETSUM 数据集上全面超过了其他对比模型,并且在 Weibo 数据上取得了具有竞争力的实验结果,证明了本文模型的有效性.由于 SCMGR 模型在对比模型中取得了较高的得分,实验中对 DSNSum 与 SCMGR 的实验结果进行了显著性检验,结果显示,除在 Weibo 数据上的 ROUGE-L 得分之外,所有结

果均通过了显著性测试. 这是因为 ROUGE-L 主要用来评估输出摘要在语法上的流畅性, 然而抽取式摘要的语言流畅性主要取决于抽取出的帖子的语言质量. 而抽取出的帖子主要是由社交媒体上的用户所撰写, 因此抽取式摘要方法在 ROUGE-L 上的性能提升有限.

(2) 整体来说, 考虑社交关系的方法比仅考虑文本内容的方法具有更高的性能. 这说明社交网络中的社交关系能够为内容分析提供额外的线索. 此外, Oracle 在 Weibo 数据上的得分相对较低, 这源于 Weibo 中的标准参考摘要为生成式, 而模型的输出为抽取式摘要.

(3) 在所有整合了网络结构关系的方法中, DSNSum 模型在 R-1, R-L 与 R-SU\* 上均取得了最高的结果, 同时在 R-L 上取得了具有竞争力的得分. 这源于在整合了社交关系的方法中, SNSR 采用基于规则的方法将社交关系建模为简单的正则项, 因此该方法对噪声关系较为敏感, 且无法抵抗网络中噪声关系的干扰, 导致模型的灵活性与泛化能力较低. SCMGR 模型利用图卷积网络整合帖子的社交关系信息与文本内容信息, 能够更加灵活地捕捉帖子之间的社交关系结构, 但是该方法忽略了真实社交关系网络中的噪声关系, 因此在整合结构的过程中仍然会引入额外的噪声偏差. DSNSum 模型则采用了一种新颖的“加噪-去噪”的学习模式, 通过向原始社交关系网络中添加噪声构造训练数据, 然后设计了一种去噪图自编码器来降低社交关系网络中的噪声关系, 从而可以学习到更加准确、对噪声关系更加鲁棒的帖子表示. 这种方式使得 DSNSum 模型能够更好地处理社交网络中的噪声关系, 从而提高了模型的性能. 其次, DSNSum 模型在处理社交网络结构时, 采用了注意力机制, 这使得模型能够自动学习识别不同节点之间关系的重要性, 从而更好地捕捉和利用社交网络结构.

(4) PacSum 取得了较低的得分, 原因在于 PacSum 是面向传统长文档的摘要方法. 该方法考虑文档中句子之间的相对位置, 而在社交媒体环境下, 不同帖子之间通常没有严格的位置关系, 因此 PacSum 方法在社交媒体环境下取得了较低的得分. SNSR 在 Weibo 数据上的性能较低, 这主要是该方法直接使用帖子的 TFIDF 表示进行重构, 所以模型倾向于优化帖子之间的 1-gram 重合度来最小化重构损失. 这种方法在 TWEETSUM 上较为有效, 这是由于 TWEETSUM 中的参考摘要是从原始帖子集合中抽取的, 因此仅考虑 1-gram 重合度即可较大概率识别出原始帖子. 而 Weibo 中的参考摘要为生成式, 因此无法直接根据 1-gram 重合度来识别原始帖子. DSNSum 能够学习帖子的分布式表示, 并且同时包含了帖子的社交关系信息与文本内容信息, 因此能够同时取得较高的 ROUGE-1 与 ROUGE-2 得分.

(5) 进一步评估 DSNSum 模型在 TWEETSUM 和 Weibo 数据集中各个话题上 (分别包含 12、10 个独立话题) 的 ROUGE-1, 2 与 SU\* 得分, 结果展示在图 3 中, 其中  $x$  轴表示话题的编号,  $y$  轴表示系统性能得分. 可以看到尽管在 Weibo 上的得分整体低于在 TWEETSUM 中的得分, 但是模型在 Weibo 上具有更小的方差, 因此在 Weibo 数据上更加稳定. 这可能说明在不同地区用户的社交行为有所不同, 由于 Weibo 上的用户主要来自同一地区 (中国), 而 Twitter 上的用户来自世界各地. 因此, 在 TWEETSUM 中内容的表达方式和社交行为可能更加复杂.




图 3 DSNSum 在 TWEETSUM 和 Weibo 上各个话题下的性能得分

## 6.2 退化实验分析

针对本文关注的两个重点问题, 进行了额外的退化实验来进行验证, 具体如下.

Q1: 利用图注意力网络来融合帖子之间的社会交互关系是否有助于提升社交媒体摘要效果? Q2: 本文设计的去噪图自编码器模块是否能够有效去除网络中的噪声关系, 从而改善摘要效果? 针对这两个问题, 在两个数据集上分别进行了退化实验, 退化实验的结果如表 5 与表 6 所示. 其中, w/o denoising 表示移除了模型中的去噪图自编码器模块, 从而禁止了模型的去噪功能. w/o GAT 则表示移除模型编码器部分的图注意力网络, 从而禁止帖子之间交互关系的捕捉. 根据实验结果, 可以得到如下观察.

表 5 DSNSum 在 TWEETSUM 数据上的退化实验结果

模型	R-1	R-2	R-L	R-SU*
DSNSum	46.506	14.285	44.157	20.757
w/o denoising	45.020	13.329	42.715	19.825
w/o GAT	44.142	12.646	41.681	19.097

表 6 DSNSum 在 Weibo 数据上的退化实验结果

模型	R-1	R-2	R-L	R-SU*
DSNSum	37.014	10.975	14.224	13.060
w/o denoising	35.313	9.7570	13.430	12.074
w/o GAT	34.355	8.9290	13.293	11.117

(1) 移除任何模块都会导致性能的降低, 该现象证明了 DSNSum 中的每个模块都对模型整体具有促进作用.

(2) 为了验证去噪过程的有效性, 本文移除 DSNSum 中的加噪与去噪过程, 对应的模型记为 w/o denoising. 实验结果显示, 移除加噪与去噪过程导致性能下降, 这直接证明了本文的假设: 社交关系网络中的噪声关系会引入额外的偏差并损害摘要性能. 理论上来说, 虚假关系会促使原本不相关的两个节点彼此靠近, 潜在关系会使得原本相关的节点彼此远离. 通过学习移除这些噪声关系, DSNSum 模型能够对社交关系网络中的噪声关系更加鲁棒, 从而学习更加可靠的帖子表示, 进而提升摘要的重要性与覆盖性.

(3) 为了探索不同社交关系的重要性, 本文进一步通过移除图注意力编码器模块来禁止相关帖子节点之间的信息传递, 对应的模型记为 w/o GAT. 实验结果显示, 去掉 GAT 模块导致模型性能大幅下降, 这说明在社交媒体环境下, 考虑帖子之间的社交关系能够有效促进对帖子内容的分析. 一方面, 图注意力网络能够从邻居节点处聚合相关的背景信息, 从而为帖子的语义理解提供更丰富的线索, 缓解单个帖子内容不足的问题; 另一方面, 帖子所处网络的拓扑结构也能够为帖子重要性的识别提供社交关系层面的线索.

## 6.3 去噪效果分析

另一个重要的问题是, 本文的去噪过程是否真的能够移除网络中的噪声关系, 并进而提升摘要性能? 本节从两个角度回答该问题: (1) 去噪之后的社交关系网络是否比原始网络包含更少的噪声关系? (2) 去噪图自编码器学到的帖子表示是否优于原始的帖子内容表示?

对于第一个问题, 为了探索 DGAE 是否真的能够提升网络的质量, 本文使用第 4.2 节得到的帖子初始内容表示, 并保持帖子的表示不变, 使用去噪前后的帖子级别社交网络结构来分别计算网络中噪声关系的比率. 结果如表 7 所示. 从结果中可以得到如下观察.

表 7 去噪之后 TWEETSUM 与 Weibo 数据中噪声关系的统计结果 (%)

数据集	虚假关系率	潜在关系率	平均噪声关系率
TWEETSUM	13.60 (↓25.01)	54.93 (↓0.86)	54.50 (↓0.87)
Weibo	45.29 (↓37.88)	49.48 (↓3.18)	46.57 (↓6.1)

注: ↓表示相比去噪之前下降的幅度

(1) 在去噪之后的网络结构中, 整体的噪声比率有所降低, 证明了去噪过程的有效性.

(2) 去噪之后, 在 TWEETSUM 与 Weibo 中的虚假关系的比率分别下降了 25.01% 与 37.88%. 这说明去噪模型更擅长去除网络中的虚假关系.

(3) 对于潜在关系的移除, 模型取得了相对较低的效果, 主要包含两个方面的原因: a) 社交网络通常具有稀疏性, 即网络中只有少数用户之间具有社交关系, 而大部分用户之间并没有社交关系. 因此, 未连接的节点对的数量要远远大于有边相连的节点对的数量, 导致准确识别潜在关系更为困难. b) 数据集中的帖子都是面向话题的, 因此

经常共享较为相关的内容,导致帖子之间经常具有较高的相似性.这也是潜在关系在网络中占据较高比重的主要原因.

为了回答第2个问题,本文通过测试 DGAE 学习到的表示是否有助于减少网络中噪声关系的比率.具体来说,我们使用原始社交关系网络,并利用与第4.2节相同的方式,分别计算基于 DGAE 表示和基于 BERT 得到的原始帖子内容表示的社交关系网络中的噪声比率.为了衡量所学表示的有效性,在计算噪声比率时,都统一使用 BERT 表示来计算帖子之间的相似度阈值  $\theta$ ,以便在相同的噪声标准下进行比较.另外,由于  $\theta$  的取值会影响噪声关系的比例,我们在实验中进一步探索了不同阈值下的噪声关系分布情况. $\theta$  的取值按如下方式计算:

$$\theta = \min\Phi + \delta(\max\Phi - \min\Phi) \quad (19)$$

其中,  $\delta$  是一个在  $[0, 1]$  范围内的参数,通过调整  $\delta$  的取值,可以改变阈值  $\theta$  的取值.具体来说,当  $\delta=0$  时,  $\theta$  取最小值  $\min\Phi$ ; 当  $\delta=1$  时,  $\theta$  取最大值  $\max\Phi$ . 因此,通过在  $[0, 1]$  范围内调整  $\delta$  的取值,可以使阈值  $\theta$  在  $[\min\Phi, \max\Phi]$  范围内变化.实验结果如图4所示,其中  $x$  轴表示公式(19)中参数的取值,  $y$  轴表示噪声关系所占的比例.(a)和(c)使用原始的 BERT 表示,(b)和(d)使用本文的 DGAE 学到的去噪之后的表示.随着阈值  $\theta$  的增加,潜在关系的比率降低,虚假关系的比率增加.总的噪声关系的比率始终保持较高的水平.然而,经过 DGAE 去噪之后,潜在关系的比率大幅下降.虚假关系的数量随着阈值的变化始终保持在较小的水平.更重要的是,去噪之后总的噪声关系比率(虚假关系+潜在关系)有所下降,证明了 DGAE 表示能够有效降低网络中的噪声关系的比率.

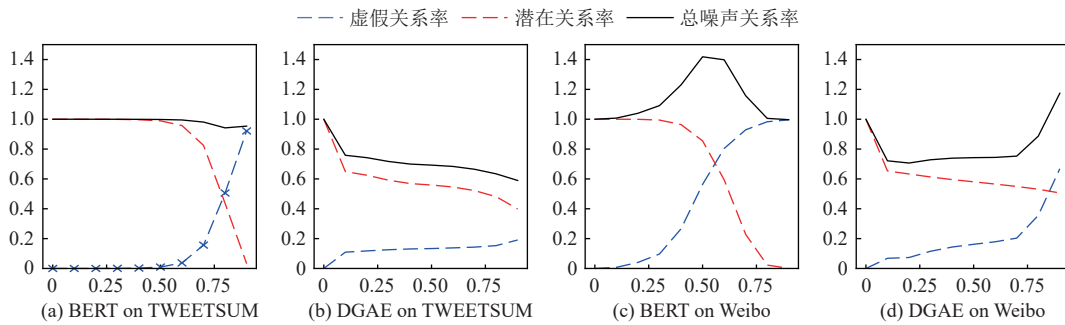


图4 真实社交关系网络中虚假关系、潜在关系以及总噪声关系率(两种噪声关系的比率之和)的相互影响

#### 6.4 噪声函数分析

本节探究两种噪声函数的噪声概率与优先级对模型结果的影响.由于空间所限,本节仅展示在 TWEETSUM 数据上的实验结果.具体来说,调整两种噪声函数中的各自的噪声添加概率,即关系插入概率  $p_i$  与关系丢失概率  $p_d$ ,探究两种噪声的概率对模型的影响.另外,两种噪声的添加顺序同样会影响实验结果,也就是说,先添加潜在关系后添加虚假关系,与先添加虚假关系后添加潜在关系会产生不同的结果.因此,本节对比两种噪声添加模式: Insert-then-Drop 与 Drop-then-Insert, 两种模式的实验结果分别如图5(a)与图5(b)所示,其中  $x$  轴表示关系插入的概率  $p_i$ ,  $y$  轴表示关系丢失的概率  $p_d$ .

从图5中可以得到如下观察.

(1) 整体来说,当  $p_d > p_i$  时,模型的整体效果较好,这揭示了社交媒体中潜在关系相比于虚假关系的存在更加普遍,这也与第6.3节中的统计结果一致.

(2) 当独立考虑两种噪声关系时,可以看到以合适的噪声概率独立地添加两种噪声关系都能够提升模型的效果,这证明了去噪函数的有效性.

(3) 在图5(a)中,关系插入优先级要高于关系丢失,当  $p_d = 1$  时,模型的结果保持不变.这是因为无论向网络中插入多少条边,网络中所有的边最终都会被丢弃.因此,这种情况下模型的性能较低,因为模型丢失帖子之间的社交关系信息.类似的,在先丢失后插入的模式种,当  $p_i = 1$  时,模型的结果同样保持不变,这是因为最终所有的节点



之间都会建立连接, 形成一个全连接网络. 然而, 相比丢失所有边来说, 连接所有节点能够取得相对较高的结果, 这是因为图注意力网络能够学习不同关系的重要性权重, 从而根据边的权重来识别虚假关系. 理想情况下, 模型会为虚假关系赋予较小的权重, 为真实的社交关系赋予较大的权重, 从而在一定程度上缓解噪声关系带来的偏差.




图5 噪声函数中两种噪声关系概率与优先级对模型 ROUGE-1 结果的影响

## 7 结论

### 7.1 总结

本文针对社交媒体情景中的挑战, 如帖子内容短小, 非正式表达, 以及社交网络中广泛存在的噪声关系等, 提出了一种无监督社交媒体文本摘要模型 DSNSum, 其由去噪图自编码器 (DGAE) 和基于稀疏重构的摘要抽取器 (SRE) 组成. DGAE 通过学习和移除社交网络中的噪声关系 (包括虚假关系和潜在关系) 来提高模型的鲁棒性. 采用社会学理论启发的噪声函数来合成训练数据, 使模型能够在缺乏标准标注数据的情况下有效识别网络中的噪声关系, 以得到更加可靠的帖子表示. 此外, DSNSum 能够通过学习帖子之间的社交关系和文本内容信息, 从而改善摘要的重要性、覆盖性和新颖性. 在两个真实社交媒体数据集上的实验结果证明了模型的有效性, 并通过定量和定性分析展示了去噪过程在减少社交网络中噪声关系, 特别是虚假关系方面的成效.

### 7.2 未来展望

对于社交媒体短文本摘要工作, 在本文模型的基础上还有很多值得探索的方向: (1) 本文所提出的评估社交网络中噪声关系阈值方法较为简单, 只能作为粗略估算的一种方式, 而难以覆盖到真实社交媒体中的复杂情况. 如何更加准确地自动识别社交网络中的噪声关系还需要进一步的探索. (2) 对于噪声函数的设计, 假设的噪声关系分布与社交网络中真实的噪声关系的分布可能存在差异. 在人工增加的噪声关系分布与真实噪声关系分布差距较大的情况下, 模型可能无法准确地识别出网络中的真实噪声关系. 因此, 探索多重不同的噪声分布设计方案, 从而更加逼近真实噪声分布的噪声函数能够有效改进去噪模型的性能. (3) 在对模型的训练过程中, 本文假设原始的社交网络不包含噪声关系, 并训练模型根据伪社交网络去重构原始社交网络, 从而使模型能够以无监督的方式进行学习. 然而真实情况中, 原始的社交网络中仍然存在噪声关系, 因此将其作为重构目标并不是最优方案. 如何在缺乏标准标注数据的情况下设计出更加精准的训练目标, 将是一个有效的改进方向.

### References:

- [1] Gu JT, Lu ZD, Li H, Li VOK. Incorporating copying mechanism in sequence-to-sequence learning. In: Proc. of the 54th Annual Meeting of the Association for Computational Linguistics (Vol. 1: Long Papers). Berlin: Association for Computational Linguistics, 2016. 1631–1640. [doi: [10.18653/v1/P16-1154](https://doi.org/10.18653/v1/P16-1154)]
- [2] Aralikkatte R, Narayan S, Maynez J, Rothe S, McDonald R. Focus attention: Promoting faithfulness and diversity in summarization. In: Proc. of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th Int'l Joint Conf. on Natural Language Processing (Vol. 1: Long Papers). Online: Association for Computational Linguistics, 2021. 6078–6095. [doi: [10.18653/v1/2021.acl-](https://doi.org/10.18653/v1/2021.acl-)

- [long.474](#)]
- [3] Jia RP, Cao Y, Fang F, Zhou YC, Fang Z, Liu YB, Wang S. Deep differential amplifier for extractive summarization. In: Proc. of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th Int'l Joint Conf. on Natural Language Processing (Vol. 1: Long Papers). Online: Association for Computational Linguistics, 2021. 366–376. [doi: [10.18653/v1/2021.acl-long.31](#)]
  - [4] Pilault J, Li R, Subramanian S, Pal C. On extractive and abstractive neural document summarization with transformer language models. In: Proc. of the 2020 Conf. on Empirical Methods in Natural Language Processing. Online: Association for Computational Linguistics, 2020. 9308–9319. [doi: [10.18653/v1/2020.emnlp-main.748](#)]
  - [5] Shi JX, Liang C, Hou L, Li JZ, Liu ZY, Zhang HW. DeepChannel: Saliency estimation by contrastive learning for extractive document summarization. In: Proc. of the 33rd AAAI Conf. on Artificial Intelligence. Honolulu: AAAI, 2019. 6999–7006. [doi: [10.1609/aaai.v33i01.33016999](#)]
  - [6] Liu YX, Liu PF. SimCLS: A simple framework for contrastive learning of abstractive summarization. In: Proc. of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th Int'l Joint Conf. on Natural Language Processing (Vol. 2: Short Papers). Online: Association for Computational Linguistics, 2021. 1065–1072. [doi: [10.18653/v1/2021.acl-short.135](#)]
  - [7] Liu YX, Liu PF, Radev D, Neubig G. BRIO: Bringing order to abstractive summarization. In: Proc. of the 60th Annual Meeting of the Association for Computational Linguistics (Vol. 1: Long Papers). Dublin: Association for Computational Linguistics, 2022. 2890–2903. [doi: [10.18653/v1/2022.acl-long.207](#)]
  - [8] Devlin J, Chang MW, Lee K, Toutanova K. BERT: Pre-training of deep bidirectional transformers for language understanding. In: Proc. of the 2019 Conf. of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Vol. 1 (Long and Short Papers). Minneapolis: Association for Computational Linguistics, 2019. 4171–4186. [doi: [10.18653/v1/N19-1423](#)]
  - [9] Lewis M, Liu YH, Goyal N, Ghazvininejad M, Mohamed A, Levy O, Stoyanov V, Zettlemoyer L. BART: Denoising sequence-to-sequence pre-training for natural language generation, translation, and comprehension. In: Proc. of the 58th Annual Meeting of the Association for Computational Linguistics. Online: Association for Computational Linguistics, 2020. 7871–7880.
  - [10] Liu Y, Lapata M. Text summarization with pretrained encoders. In: Proc. of the 2019 Conf. on Empirical Methods in Natural Language Processing and the 9th Int'l Joint Conf. on Natural Language Processing. Hong Kong: Association for Computational Linguistics, 2019. 3730–3740. [doi: [10.18653/v1/D19-1387](#)]
  - [11] Pietruszka M, Borchmann L, Garncaek L. Sparsifying transformer models with trainable representation pooling. In: Proc. of the 60th Annual Meeting of the Association for Computational Linguistics (Vol. 1: Long Papers). Dublin: Association for Computational Linguistics, 2022. 8616–8633. [doi: [10.18653/v1/2022.acl-long.590](#)]
  - [12] Guo M, Ainslie J, Uthus D, Ontanon S, Ni J, Sung YH, Yang YF. LongT5: Efficient text-to-text Transformer for long sequences. In: Findings of the Association for Computational Linguistics: NAACL 2022. Seattle: Association for Computational Linguistics, 2022. 724–736. [doi: [10.18653/v1/2022.findings-naacl.55](#)]
  - [13] Rothe S, Narayan S, Severyn A. Leveraging pre-trained checkpoints for sequence generation tasks. Trans. of the Association for Computational Linguistics. 2020, 8, 264–280. [doi: [10.1162/tacl\\_a\\_00313](#)]
  - [14] Ge SY, Huang JX, Meng Y, Han JW. FineSum: Target-oriented, fine-grained opinion summarization. In: Proc. of the 16th ACM Int'l Conf. on Web Search and Data Mining. Singapore: ACM, 2023. 1093–1101. [doi: [10.1145/3539597.3570397](#)]
  - [15] Yoon S, Chan HP, Han JW. PDSum: Prototype-driven continuous summarization of evolving multi-document sets stream. In: Proc. of the 2023 ACM Web Conf. Austin: ACM, 2023. 1650–1661. [doi: [10.1145/3543507.3583371](#)]
  - [16] Amplayo RK, Lapata M. Unsupervised opinion summarization with noising and denoising. In: Proc. of the 58th Annual Meeting of the Association for Computational Linguistics. Online: Association for Computational Linguistics, 2020. 1934–1945. [doi: [10.18653/v1/2020.acl-main.175](#)]
  - [17] Bražinskas A, Lapata M, Titov I. Unsupervised opinion summarization as copycat-review generation. In: Proc. of the 58th Annual Meeting of the Association for Computational Linguistics. Online: Association for Computational Linguistics, 2020. 5151–5169. [doi: [10.18653/v1/2020.acl-main.461](#)]
  - [18] Andy A, Wijaya DT, Callison-Burch C. Winter is here: Summarizing Twitter streams related to pre-scheduled events. In: Proc. of the 2nd Workshop on Storytelling. Florence: Association for Computational Linguistics, 2019. 112–116. [doi: [10.18653/v1/W19-3412](#)]
  - [19] Gillani M, Ilyas MU, Saleh S, Alowibdi JS, Aljohani N, Alotaibi FS. Post summarization of microblogs of sporting events. In: Proc. of the 26th Int'l Conf. on World Wide Web Companion. Perth, 2017. 59–68. [doi: [10.1145/3041021.3054146](#)]
  - [20] Zogan H, Razzak I, Jameel S, Xu GD. DepressionNet: A novel summarization boosted deep framework for depression detection on social media. In: Proc. of the 44th Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. 2021. 133–142. [doi: [10.1145/3404835.3462938](#)]

- [21] Khan MAH, Bollegala D, Liu GW, Sezaki K. Multi-tweet summarization of real-time events. In: Proc. of the 2013 Int'l Conf. on Social Computing. Alexandria: IEEE, 2013. 128–133. [doi: [10.1109/SocialCom.2013.26](https://doi.org/10.1109/SocialCom.2013.26)]
- [22] Wang RY, Luo SL, Pan LM, Wu ZT, Yuan YJ, Chen QR. Microblog summarization using paragraph vector and semantic structure. *Computer Speech & Language*, 2019, 57: 1–19. [doi: [10.1016/j.csl.2019.01.006](https://doi.org/10.1016/j.csl.2019.01.006)]
- [23] Hodas NO, Lerman K. The simple rules of social contagion. *Scientific Reports*, 2014, 4: 4343. [doi: [10.1038/srep04343](https://doi.org/10.1038/srep04343)]
- [24] Cha M, Haddadi H, Benevenuto F, Gummadi K. Measuring user influence in Twitter: The million follower fallacy. In: Proc. of the 4th Int'l AAAI Conf. on Weblogs and Social Media. Washington: AAAI, 2010. 10–17. [doi: [10.1609/icwsm.v4i1.14033](https://doi.org/10.1609/icwsm.v4i1.14033)]
- [25] Kwak H, Lee C, Park H, Moon S. What is Twitter, a social network or a news media? In: Proc. of the 19th Int'l Conf. on World Wide Web. Raleigh: ACM, 2010. 591–600. [doi: [10.1145/1772690.1772751](https://doi.org/10.1145/1772690.1772751)]
- [26] Petrovic S, Osborne M, Lavrenko V. RT to win! Predicting message propagation in twitter. In: Proc. of the 5th Int'l AAAI Conf. on Web and Social Media. Barcelona: AAAI, 2010. 586–589. [doi: [10.1609/icwsm.v5i1.14149](https://doi.org/10.1609/icwsm.v5i1.14149)]
- [27] He RF, Duan XY. Twitter summarization based on social network and sparse reconstruction. In: Proc. of the 32nd AAAI Conf. on Artificial Intelligence. New Orleans: AAAI, 2018. 5787–5794. [doi: [10.1609/aaai.v32i1.12058](https://doi.org/10.1609/aaai.v32i1.12058)]
- [28] Abelson RP. Whatever became of consistency theory? *Personality and Social Psychology Bulletin*, 1983, 9(1): 37–54. [doi: [10.1177/0146167283091006](https://doi.org/10.1177/0146167283091006)]
- [29] Shalizi CR, Thomas AC. Homophily and contagion are generically confounded in observational social network studies. *Sociological Methods & Research*, 2011, 40(2): 211–239. [doi: [10.1177/0049124111404820](https://doi.org/10.1177/0049124111404820)]
- [30] Veličković P, Cucurull G, Casanova A, Romero A, Lio P, Bengio Y. Graph attention networks. arXiv:1710.10903, 2018.
- [31] Hu BT, Chen QC, Zhu FZ. LCSTS: A large scale Chinese short text summarization dataset. In: Proc. of the 2015 Conf. on Empirical Methods in Natural Language Processing. Lisbon: Association for Computational Linguistics, 2015. 1967–1972. [doi: [10.18653/v1/D15-1229](https://doi.org/10.18653/v1/D15-1229)]
- [32] Kim B, Kim H, Kim G. Abstractive summarization of reddit posts with multi-level memory networks. In: Proc. of the 2019 Conf. of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Vol. 1 (Long and Short Papers). Minneapolis: Association for Computational Linguistics, 2019. 2519–2531. [doi: [10.18653/v1/N19-1260](https://doi.org/10.18653/v1/N19-1260)]
- [33] Ma SM, Sun X, Lin JY, Wang HF. Autoencoder as assistant supervisor: Improving text representation for Chinese social media text summarization. In: Proc. of the 56th Annual Meeting of the Association for Computational Linguistics (Vol. 2: Short Papers). Melbourne: Association for Computational Linguistics, 2018. 725–731. [doi: [10.18653/v1/P18-2115](https://doi.org/10.18653/v1/P18-2115)]
- [34] Ma SM, Sun X, Xu JJ, Wang HF, Li WJ, Su Q. Improving semantic relevance for sequence-to-sequence learning of Chinese social media text summarization. In: Proc. of the 55th Annual Meeting of the Association for Computational Linguistics (Vol. 2: Short Papers). Vancouver: Association for Computational Linguistics, 2017. 635–640. [doi: [10.18653/v1/P17-2100](https://doi.org/10.18653/v1/P17-2100)]
- [35] Völske M, Potthast M, Syed S, Stein B. TL;DR: Mining reddit to learn automatic summarization. In: Proc. of the Workshop on New Frontiers in Summarization. Copenhagen: Association for Computational Linguistics, 2017. 59–63. [doi: [10.18653/v1/W17-4508](https://doi.org/10.18653/v1/W17-4508)]
- [36] Chua F, Asur S. Automatic summarization of events from social media. In: Proc. of the 7th Int'l AAAI Conf. on Weblogs and Social Media. Cambridge: AAAI, 2013. 81–90. [doi: [10.1609/icwsm.v7i1.14394](https://doi.org/10.1609/icwsm.v7i1.14394)]
- [37] Ganesan K, Zhai CX, Viegas E. Micropinion generation: An unsupervised approach to generating ultra-concise summaries of opinions. In: Proc. of the 21st Int'l Conf. on World Wide Web. Lyon: ACM, 2012. 869–878. [doi: [10.1145/2187836.2187954](https://doi.org/10.1145/2187836.2187954)]
- [38] Inouye D, Kalita JK. Comparing twitter summarization algorithms for multiple post summaries. In: Proc. of the 3rd IEEE Int'l Conf. on Privacy, Security, Risk and Trust and the 3rd IEEE Int'l Conf. on Social Computing. Boston: IEEE, 2011. 298–306. [doi: [10.1109/PASSAT/SocialCom.2011.31](https://doi.org/10.1109/PASSAT/SocialCom.2011.31)]
- [39] Sharifi B, Hutton MA, Kalita J. Summarizing microblogs automatically. In: Proc. of the 2010 Annual Conf. of the North American Chapter of the Association for Computational Linguistics. Los Angeles: Association for Computational Linguistics, 2010. 685–688.
- [40] Dutta S, Ghatak S, Roy M, Ghosh S, Das AK. A graph based clustering technique for tweet summarization. In: Proc. of the 4th Int'l Conf. on Reliability, Infocom Technologies and Optimization (ICRITO) (Trends and Future Directions). IEEE, 2015. 1–6. [doi: [10.1109/ICRITO.2015.735927](https://doi.org/10.1109/ICRITO.2015.735927)]
- [41] Xu W, Grishman R, Meyers A, Ritter A. A preliminary study of tweet summarization using information extraction. In: Proc. of the Workshop on Language Analysis in Social Media. Atlanta: Association for Computational Linguistics, 2013. 20–29.
- [42] Keswani V, Celis LE. Dialect diversity in text summarization on Twitter. In: Proc. of the 2021 Web Conf. Ljubljana: ACM, 2021. 3802–3814. [doi: [10.1145/3442381.3450108](https://doi.org/10.1145/3442381.3450108)]
- [43] Cha M, Haddadi H, Benevenuto F, Gummadi K. Measuring user influence in Twitter: The million follower fallacy. In: Proc. of the 4th Int'l AAAI Conf. on Weblogs and Social Media. Washington: AAAI, 2010. 10–17. [doi: [10.1609/icwsm.v4i1.14033](https://doi.org/10.1609/icwsm.v4i1.14033)]

- [44] Alsaedi N, Burnap P, Rana O. Automatic summarization of real world events using Twitter. In: Proc. of the 10th Int'l AAAI Conf. on Web and Social Media. Cologne: AAAI, 2016. 511–514. [doi: [10.1609/icwsm.v10i1.14766](https://doi.org/10.1609/icwsm.v10i1.14766)]
- [45] Liu XH, Li YT, Wei FR, Zhou M. Graph-based multi-tweet summarization using social signals. In: Proc. of the 2012 COLING. Mumbai: The COLING 2012 Organizing Committee, 2012. 1699–1714.
- [46] Duan YJ, Chen ZM, Wei FR, Zhou M, Shum HY. Twitter topic summarization by ranking Tweets using social influence and content quality. In: Proc. of the 2012 COLING. Mumbai: The COLING 2012 Organizing Committee, 2012. 763–780.
- [47] Li J, Gao W, Wei ZY, Peng BL, Wong KF. Using content-level structures for Summarizing microblog repost trees. In: Proc. of the 2015 Conf. on Empirical Methods in Natural Language Processing. Lisbon: Association for Computational Linguistics, 2015. 2168–2178. [doi: [10.18653/v1/D15-1259](https://doi.org/10.18653/v1/D15-1259)]
- [48] Dutta S, Das AK, Bhattacharya A, Dutta G, Parikh KK, Das A, Ganguly D. Community detection based tweet summarization. In: Emerging Technologies in Data Mining and Information Security. Singapore: Springer, 2019. 797–808. [doi: [10.1007/978-981-13-1498-8\\_70](https://doi.org/10.1007/978-981-13-1498-8_70)]
- [49] Han Y, Xu J, Fang BX, Zhou B, Jia Y. Structural supportiveness theory on social networks. Chinese Journal of Computers, 2014, 37(4): 905–914 (in Chinese with English abstract). [doi: [10.3724/SP.J.1016.2014.00905](https://doi.org/10.3724/SP.J.1016.2014.00905)]
- [50] Cao JX, Wu JL, Shi W, Liu B, Zheng X, Luo JZ. Sina microblog information diffusion analysis and prediction. Chinese Journal of Computers, 2014, 37(4): 779–790 (in Chinese with English abstract). [doi: [10.3724/SP.J.1016.2014.00779](https://doi.org/10.3724/SP.J.1016.2014.00779)]
- [51] Chang Y, Wang XH, Mei QZ, Liu Y. Towards Twitter context summarization with user influence models. In: Proc. of the 6th ACM Int'l Conf. on Web Search and Data Mining. Rome: ACM, 2013. 527–536. [doi: [10.1145/2433396.2433464](https://doi.org/10.1145/2433396.2433464)]
- [52] He RF, Liu HY, Zhao LL. SCHC: Incorporating social contagion and hashtag consistency for topic-oriented social summarization. In: Proc. of the 26th Int'l Conf. on Database Systems for Advanced Applications. Taipei: Springer, 2021. 641–657. [doi: [10.1007/978-3-030-73197-7\\_44](https://doi.org/10.1007/978-3-030-73197-7_44)]
- [53] Liu HY, He RF, Zhao LL, Wang HC, Wang RF. SCMGR: Using social context and multi-granularity relations for unsupervised social summarization. In: Proc. of the 30th ACM Int'l Conf. on Information and Knowledge Management. Virtual Event: ACM, 2021. 1058–1068. [doi: [10.1145/3459637.3482476](https://doi.org/10.1145/3459637.3482476)]
- [54] Doan XD, Nguyen LM, Bui KHN. Multi graph neural network for extractive long document summarization. In: Proc. of the 29th Int'l Conf. on Computational Linguistics. Gyeongju: Int'l Committee on Computational Linguistics, 2022. 5870–5875.
- [55] Song MY, Feng Y, Jing LP. HISum: Hyperbolic interaction model for extractive multi-document summarization. In: Proc. of the 2023 ACM Web Conf. Austin: ACM, 2023. 1427–1436. [doi: [10.1145/3543507.3583197](https://doi.org/10.1145/3543507.3583197)]
- [56] Mao QR, Zhu HD, Liu JN, Ji C, Peng H, Li JX, Wang LH, Wang Z. MuchSUM: Multi-channel graph neural network for extractive summarization. In: Proc. of the 45th Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. Madrid: ACM, 2022. 2617–2622. [doi: [10.1145/3477495.3531906](https://doi.org/10.1145/3477495.3531906)]
- [57] Kipf TN, Welling M. Variational graph auto-encoders. arXiv:1611.07308, 2016.
- [58] Kipf TN, Welling M. Semi-supervised classification with graph convolutional networks. arXiv:1609.02907, 2017.
- [59] Freitag M, Roy S. Unsupervised natural language generation with denoising autoencoders. In: Proc. of the 2018 Conf. on Empirical Methods in Natural Language Processing. Brussels: Association for Computational Linguistics, 2018. 3922–3929. [doi: [10.18653/v1/D18-1426](https://doi.org/10.18653/v1/D18-1426)]
- [60] Wang L, Zhao W, Jia SY, Li SJ, Liu JM. Denoising based sequence-to-sequence pre-training for text generation. In: Proc. of the 2019 Conf. on Empirical Methods in Natural Language Processing and the 9th Int'l Joint Conf. on Natural Language Processing (EMNLP-IJCNLP). Hong Kong: Association for Computational Linguistics, 2019. 4003–4015. [doi: [10.18653/v1/D19-1412](https://doi.org/10.18653/v1/D19-1412)]
- [61] Coscia M, Neffke F. Network backboning with noisy data. arXiv:1701.07336, 2017.
- [62] Serrano MÁ, Boguñá M, Vespignani A. Extracting the multiscale backbone of complex weighted networks. Proc. of the National Academy of Sciences of the United States of America, 2009, 106(16): 6483–6488. [doi: [10.1073/pnas.0808904106](https://doi.org/10.1073/pnas.0808904106)]
- [63] He RF, Zhao LL, Liu HY. TWEETSUM: Event oriented social summarization dataset. In: Proc. of the 28th Int'l Conf. on Computational Linguistics. Barcelona: Int'l Committee on Computational Linguistics, 2020. 5731–5736. [doi: [10.18653/v1/2020.coling-main.504](https://doi.org/10.18653/v1/2020.coling-main.504)]
- [64] Cacioppo JT, Fowler JH, Christakis NA. Alone in the crowd: The structure and spread of loneliness in a large social network. Journal of Personality and Social Psychology, 2009, 97(6): 977–991. [doi: [10.1037/a0016076](https://doi.org/10.1037/a0016076)]
- [65] Christakis NA, Fowler JH. Social contagion theory: Examining dynamic social networks and human behavior. Statistics in Medicine, 2013, 32(4): 556–577. [doi: [10.1002/sim.5408](https://doi.org/10.1002/sim.5408)]
- [66] Defferrard M, Bresson X, Vandergheynst P. Convolutional neural networks on graphs with fast localized spectral filtering. In: Proc. of the 30th Int'l Conf. on Neural Information Processing Systems. Barcelona: Curran Associates Inc., 2016. 3844–3852.

- [67] Yasunaga M, Zhang R, Meelu K, Pareek A, Srinivasan K, Radev D. Graph-based neural multi-document summarization. In: Proc. of the 21st Conf. on Computational Natural Language Learning. Vancouver: Association for Computational Linguistics, 2017. 452–462. [doi: [10.18653/v1/K17-1045](https://doi.org/10.18653/v1/K17-1045)]
- [68] Nguyen DQ, Vu T, Nguyen AT. BERTweet: A pre-trained language model for English Tweets. In: Proc. of the 2020 Conf. on Empirical Methods in Natural Language Processing: System Demonstrations. Online: Association for Computational Linguistics, 2020. 9–14. [doi: [10.18653/v1/2020.emnlp-demos.2](https://doi.org/10.18653/v1/2020.emnlp-demos.2)]
- [69] Lin CY. ROUGE: A package for automatic evaluation of summaries. In: Text Summarization Branches Out. Barcelona: Association for Computational Linguistics, 2004. 74–81.
- [70] Radev DR, Blair-Goldensohn S, Zhang Z. Experiments in single and multi-document summarization using MEAD. In: Proc. of the 1st Document Understanding Conf. 2001. 1194–1197.
- [71] Gong YH, Liu X. Generic text summarization using relevance measure and latent semantic analysis. In: Proc. of the 24th Annual Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. New Orleans: ACM, 2001. 19–25. [doi: [10.1145/383952.383955](https://doi.org/10.1145/383952.383955)]
- [72] Erkan G, Radev DR. LexRank: Graph-based lexical centrality as salience in text summarization. Journal of Artificial Intelligence Research, 2004, 22(1): 457–479.
- [73] He ZY, Chen C, Bu JJ, Wang C, Zhang LJ, Cai D, He XF. Document summarization based on data reconstruction. In: Proc. of the 26th AAAI Conf. on Artificial Intelligence. Toronto: AAAI Press, 2012. 620–626.
- [74] Liu H, Yu HL, Deng ZH. Multi-document summarization based on two-level sparse representation model. In: Proc. of the 29th AAAI Conf. on Artificial Intelligence. Austin: AAAI Press, 2015. 196–202.
- [75] Zheng H, Lapata M. Sentence centrality revisited for unsupervised summarization. In: Proc. of the 57th Annual Meeting of the Association for Computational Linguistics. Florence: Association for Computational Linguistics, 2019. 6236–6247. [doi: [10.18653/v1/P19-1628](https://doi.org/10.18653/v1/P19-1628)]
- [76] Wang KX, Chang BB, Sui ZF. A spectral method for unsupervised multi-document summarization. In: Proc. of the 2020 Conf. on Empirical Methods in Natural Language Processing. Online: Association for Computational Linguistics, 2020. 435–445. [doi: [10.18653/v1/2020.emnlp-main.32](https://doi.org/10.18653/v1/2020.emnlp-main.32)]

#### 附中文参考文献:

- [49] 韩毅, 许进, 方滨兴, 周斌, 贾焰. 社交网络的结构支撑理论. 计算机学报, 2014, 37(4): 905–914. [doi: [10.3724/SP.J.1016.2014.00905](https://doi.org/10.3724/SP.J.1016.2014.00905)]
- [50] 曹玖新, 吴江林, 石伟, 刘波, 郑啸, 罗军舟. 新浪微博网信息传播分析与预测. 计算机学报, 2014, 37(4): 779–790. [doi: [10.3724/SP.J.1016.2014.00779](https://doi.org/10.3724/SP.J.1016.2014.00779)]



贺瑞芳(1979—), 女, 博士, 教授, CCF 专业会员, 主要研究领域为自然语言处理, 社交媒体挖掘, 机器学习.



刘焕宇(1997—), 男, 硕士, 主要研究领域为自然语言处理, 文本摘要.



赵堂龙(2000—), 男, 硕士生, 主要研究领域为自然语言处理, 文本摘要.