PK-CHAT：指针网络引导的知识驱动生成式对话模型

Cheng Deng[1], Bo Tong[1], Luoyi Fu[1], Jiaxin Ding[1],Dexing Cao[1],Xinbing Wang[1],Chenghu Zhou[1,2]

[1] 上海交通大学[2] 中国科学院地理科学与资源研究所{davendw, bool tbb, yiluofu}@sjtu.edu.cn

arXiv:2304.00592v1 [cs.CL] 2 Apr 2023

摘要

在端到端对话系统的研究中，利用现实世界知识生成自然、流畅、类人且答案正确的话语至关重要。然而，由于词汇表外问题或神经网络参数中知识有误，特定领域的对话系统可能会出现语意不连贯的情况，并在回答问题时引入错误的外部信息。在本研究中，我们提出**PK-Chat**，一种融合统一预训练语言模型和知识图谱上的指针网络的**指**针网络引导的**知**识驱动生成式对话模型。PK-Chat 在对话中生成的词语来自对词表的预测以及对外部知识图谱知识的直接预测。此外，我们基于PK-Chat 构建了一个面向地球科学学术场景的对话系统。最后，我们构建了一个学术对话基准，用于评估学术场景下对话系统的质量，源代码也已在线发布。[1]

索引词— 对话系统，指针网络，学术知识图谱，自然语言生成

1. 引言

使用 PLATO 和 GPT 等语言模型构建对话系统 [1, 2] 已成为主流研究方向；在此类模型上进行微调可以生成类人对话回复。然而，现有的生成式对话系统侧重于提供通用回复，这可能导致回复缺乏领域专业知识和语义连贯性 [3]。

知识图谱（如 Freebase [4], Yago [5] ）被引入对话系统 [6] ，以弥补领域专家知识的缺失。在这些工作中，知识图谱被嵌入潜在语义空间中的向量，并利用嵌入向量生成相关的文本候选集 [7]。然而，这些方法忽略了语义连贯性，因为每个话语邻近候选项的概率都是独立计算的，没有考虑候选话语与上下文输入之间的关系 [8]。此外，预训练模型会获取所引用知识的位置信息；如果知识图谱中的词语未出现在预训练模型的分词器中，或出现概率较低，那么这些知识便属于未见知识和词汇表外词语，因此无法识别其具体含义。在这种情况下，网络记忆的知识可能会在回复中被误用。 [9]。

面对知识驱动型生成式对话模型存在的问题，我们引入指针网络 [10, 11] ，将信息从原始输入文本传递到输出文本，同时保留详细信息。以文本摘要为例，原始语料库中可能包含训练期间未见过的词语。对于未采用指针网络的模型，原文中的细节难以还原，生成的摘要也可能包含大量不准确的信息；而采用指针网络时，遇到未登录词语便可从原文中保留相关内容，从而还原这些细节 [12, 11]。

在本研究中，我们设计了一种由指针网络引导的知识驱动型生成式对话模型，并使用 GAKG [13]进行训练，以基于相应的地质学知识，与用户围绕特定知识进行流畅自然、融入知识的对话。系统概览如图 1 所示。本文的贡献如下：

1 本研究介绍了 **PK-Chat**，这是一种新颖的对话生成模型，通过灵活的自注意力机制将预训练语言模型与指针生成网络相结合。凭借这一先进方法，PK-Chat 在多个基准数据集上的表现均优于已有基线。

2 PK-Chat 创新性地采用与统一的预训练语言模型相结合的指针网络，以引导领域特定对话生成，这是推动该领域先进水平发展的重要贡献。

3 除了 PK-Chat，我们还构建了 GA-Dialogue，这是首个词语来源于 GAKG 的学术对话数据集。该数据集的推出是一项重大进展，因为它可用于训练其他对话生成模型，进一步推动这一前景广阔领域的发展。

2. 方法论

在本节中，我们介绍 **PK-Chat**，这是一种新颖的对话生成模型，通过自注意力机制结合统一预训练语言模型与指针生成网络。PK-Chat 旨在基于学术知识图谱，利用特定领域知识生成流畅自然的文本。为此，PK-Chat 由对话生成模型、知识图谱检索和关键词抽取子系统组成，这些子系统协同工作以产出智能且能根据上下文调整的

[1] https://github.com/iiot-tbb/Dialogue_DDE

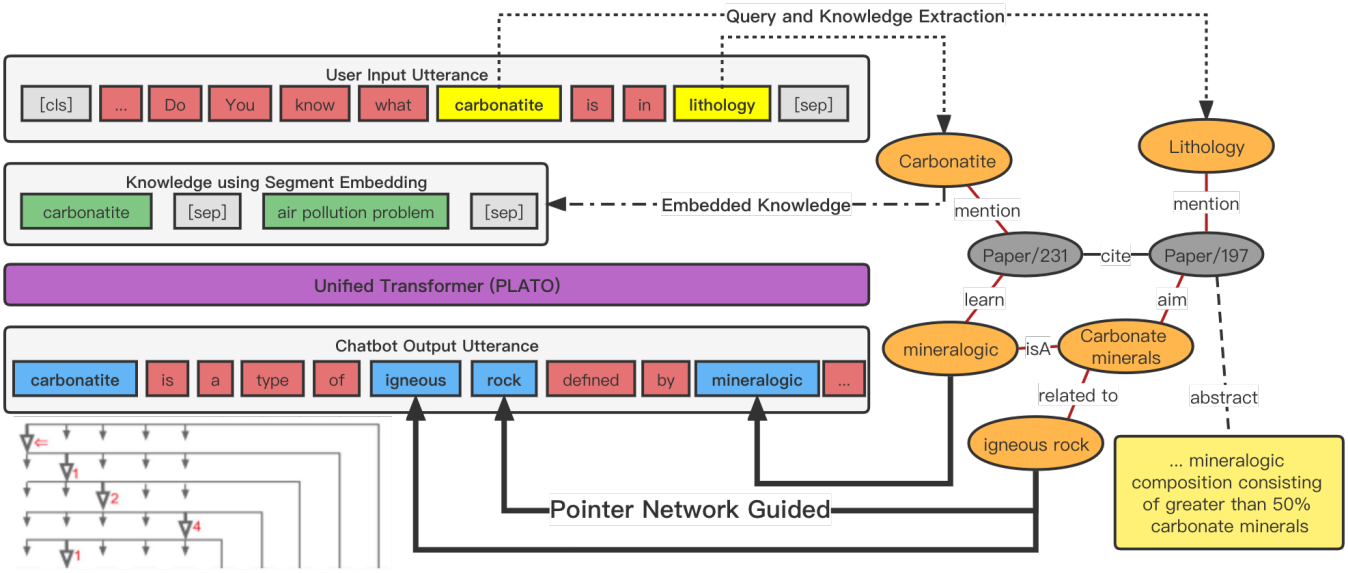


图 1：PK-Chat 与地球科学学术知识图谱概览。

用户查询响应。

首先，当用户输入话语时，模型会判断该输入是否与当前引用的知识范围相关。假设当前用户话语与引用的知识相冲突，则会启动知识抽取算法，从文本中提取关键词信息或实体信息。随后，利用图查询语句，根据知识图谱中实体的关键词查询特定的关联三元组信息，并将与该节点直接相连的所有边和尾实体召回，作为模型的知识输入部分；再将其与用户话语结合，生成回复。

2.1. 对话生成

为了生成合理的对话回复，生成模型应充分理解上述对话历史信息和背景知识，从而确保回复足够准确且连贯。

由于统一双向、单向和序列到序列目标函数后，我们可以直接微调预训练语言模型 UniLM[14] ，使其同时支持自然语言理解、自然语言生成和对话任务，且对话任务也能从中受益，因此我们采用了基于 UniLM-PLATO 的对话语言模型作为 PK-Chat 的主干网络。该模型采用参数共享的自注意力机制 Transformer，并在社交媒体语料库上训练。我们使用第 3 节所示 GAKG 数据中的对话语料库对其进行微调。此外，我们任务中的损失函数包括：用于对话回复生成和指针生成部分的负对数似然函数；用于预测回复中应包含哪些词语的词袋模型损失函数；以及用于主题切换的交叉熵损失函数。

回复生成 对于给定的上下文信息 c 和选定的隐变量 z，回复表示为 $P(r \mid c,z)$，其依据是这一点。其中$z \in [1,K]$, 每个特定的 z 值都对应一种潜在的语义行为；给定上下文信息和回复内容后，可通过 $\text{argmax}(P(z \mid r,c))$ 确定相应的隐变量。

在 PK-Chat 中，回复生成主要由离散隐变量、内容和知识信息构成。并采用最大似然估计函数作为损失函数，如公式 1 所示。

$$\begin{aligned}\mathcal{L}_{NLL} &= -\mathbb{E}_{z\sim p(\mathbf{z}|c,k,r)} \log p(r \mid c,k,z) \\ &= -\mathbb{E}_{z\sim p(\mathbf{z}|c,k,r)} \sum_{t=1}^{T} \log p\left(r_t \mid c,k,z,r_{<t}\right),\end{aligned} \tag{1}$$

其中，z是根据（c,k,r）得到的离散隐变量，并依据概率$p(\mathbf{z} \mid c,k,r)$进行采样。隐变量识别任务用于获得隐变量后验概率的分布。c 表示上述对话信息，k 表示外部知识信息。并且，$p(\mathbf{z} \mid c,k,r)$是一个 Softmax 激活函数，如公式 2 所示，

$$p(\mathbf{z} \mid c,k,r) = \text{softmax}\left(W_1 h_{[M]} + b_1\right) \in \mathbb{R}^K, \tag{2}$$

其中，$z \in \mathbb{R}^K$和$h_{[M]} \in \mathbb{R}^K$ 是特殊状态标记位置最后一层的状态标记。$W_1 \in \mathbb{R}^{K\times D}$ 和$b_1 \in \mathbb{R}^K$ 表示可训练参数。

在回复生成过程中，对每个词w 的预测都由对应的词列表、上下文和嵌入知识信息共同决定。PK-Chat 采用指针网络，使其能够更准确地引用外部知识。概率的计算方式如公式 3 所示，

$$P(w) = \lambda_{gen} P_{\text{vocab}}(w) + \left(1-\lambda_{gen}\right) \sum_{i:w_i=w} a_i^t, \tag{3}$$

其中 λ_{gen} = Sigmoid函数$(W_2 h_D + b_2)$，W_2 和b_2 是可训练参数，h_D 是中间生成结果的隐藏状态，而a 表示上下文中知识嵌入位置与指针的预测。

除了生成对话回复这一直接任务目标的负对数似然估计外，模型训练过程中还加入了词袋模型的损失函数，以通过预测词袋中的词语来学习隐藏变量z；具体而言，通过z最后一层的隐藏状态，预测回复中应包含的词语。这种多任务模型还可以加快模型训练的收敛速度。损失函数如公式4所示。

$$\begin{aligned}\mathcal{L}_{BOW} &= -\mathbb{E}_{z\sim p(\mathbf{z}|c,k,r)}\sum_{t=1}^{T}\log p\left(r_t \mid c,k,z\right)\\ &= -\mathbb{E}_{z\sim p(\mathbf{z}|c,k,r)}\sum_{t=1}^{T}\log\frac{e^{f_{r_t}}}{\sum_{v\in V}e^{f_v}},\end{aligned} \tag{4}$$

其中V表示词列表的大小，f是 Softmax 函数$f = \text{softmax}(W_3 h_z + b_3) \in \mathbb{R}^{|V|}$，用于预测目标生成中的词语；$f_{r_t}$表示每个时刻生成词语的概率值。此预测与各词语的顺序无关，而是通过这种学习方式，使隐藏状态变量能够捕获更多全局信息。

主题切换 在实践中，我们应根据适当的话题选择正确的外部知识，并通过比较当前用户的词语与上下文来判断是否需要切换知识。因此，有必要判断是否进行主题切换，以便在适当的时机选择不同的知识。在此模型中，主题切换是一个二分类任务，用于判断当前知识是否与当前用户话语匹配；如果匹配，则保留当前主题知识，并继续围绕当前话题进行对话。如果当前知识与用户提出的问题不匹配，则触发关键词提取模块，并在知识图谱中查询提取出的关键词所对应的实体和边信息。我们采用交叉熵损失函数，如公式 5 所示。

$$\mathcal{L}_{TS} = -\log p\left(l_{\text{true}} = 1 \mid k,c,r^{+}\right) - \log p\left(l_{\text{true}} = 0 \mid k,c,r^{-}\right). \tag{5}$$

将对话过程中给出的知识标记为 $l_{\text{true}} = 1$，随机抽取其他话题中的知识，并将其标记为 $l_{\text{true}} = 0$。总体而言，整个模型的损失函数为:

$$\mathcal{L} = \mathcal{L}_{NLL} + \mathcal{L}_{BOW} + \mathcal{L}_{TS}, \tag{6}$$

其中，$\mathcal{L}_{NLL}$直接作用于生成目标，$\mathcal{L}_{BOW}$作用于隐藏状态的学习，并辅助生成任务。$\mathcal{L}_{TJ}$用于主题分类，因此整个模型采用多任务学习方法。

2.2. 关键词抽取

当用户的话语中提及知识图谱中的实体时，在与用户交流过程中，将通过基于规则的关键词提取方法、TF-IDF [15], TextRank [16] 和 BiL- STM+CRF [17] 命名实体识别方法，提取当前实体。

- 我们采用基于规则的方法，通过构造类似*"(what|which|where)(is|are)(the)[a-z]{0,5}?"* 的正则表达式来匹配疑问短语，从而快速定位相应的关键词。
- 我们使用 TF-IDF 和 TextRank，通过将某个词的词频与其逆文档频率相乘来获取最重要的词语，以表示该词语的重要性。
- 我们还使用 BiLSTM-CRF 模型，将用户对话中的知识信息抽取定义为用于关键词抽取的序列标注任务。

在关键词抽取训练数据方面，TF-IDF 和 TextRank 属于无监督方法，无需构建标注数据进行训练，因此，信息抽取的数据集构建主要是为了使 BILSTM+CRF 模型在这一关键词抽取任务中取得良好表现。根据本文对话数据的特点，对话中的实体信息是对知识图谱中实体的引用，因此，这部分的标注任务不需要大量人工标注；我们只需搜索并定位对话中的实体，再进行自动标注。

2.3 基于知识图谱的检索

为了确保知识检索的效率，我们为外部知识图谱选择了合理的存储方式。本文选择了地球科学领域的学术知识图谱 GAKG，以部署学术对话系统。

GAKG 是一个由论文插图、文本和文献计量数据构成的集合，目前是规模最大、内容最全面的地球科学学术知识图谱，包含超过 1.2 亿个三元组，11 种概念通过 19 种关系相连，并以资源描述框架格式存储。我们下载了 GAKG 的完整副本，并将其存储在图数据库 Neo4J 中。之后，我们构建了 GA-Dialogue 对话数据集，用于训练学术聊天机器人。首先，我们从 GAKG 知识图谱中随机抽取单个头实体的所有关联边和尾实体信息，基于抽样信息构建特定的对话场景，并围绕该实体的信息展开对话，即在对话中引用该实体的信息进行回复。为了提高对话数据集的质量，我们邀请了 20 位了解 GAKG 详情的地理学家参与构建，并让他们保留实体的标签格式。GA-Dialogue 中共构建了 550 个对话场景和 3,615 轮对话。每个场景中用户的平均发言次数为**6.7**。

然而，对话数据集的数量还不够多，因此我们通过清洗和构建公开数据集来增加数据量。我们使用百度DuConv [18] 和百度DuRec- Dial [19] 对话数据集作为外部数据集引入。DuConv数据集中包含29,858个场景对话，每个场景平均有**9**轮对话。为了使该对话数据集中的数据与我们的GAKG中的对话数据保持一致，我们将对话数据集中的两类知识——对话目标和知识——整合为统一的外部知识。DuRecDial数据集中包含10,200个场景对话，每个场景平均有**15** 轮对话。该对话数据集中有三类对话相关知识：对话目标、知识和用户画像。我们将其中汇总的对话目标、知识和用户画像整合为知识。这样，数据格式便与GAKG的对话格式保持一致。

		自动评估			人工评估				
数据集	模型	BLEU-1/2	Distinct-1/2	知识召回率/精确率/F1值	可读性	相关性	一致性	信息丰富度	自然度
GA-Dialogue（第1部分）	PLATO (Unidirect)	0.054/0.042	0.099/0.270	0.002/0.011/0.003	0.60	0.50	0.502	0.40	0.37
	PLATO	0.415/0.354	**0.165**/0.361	0.099/0.218/0.124	2.67	2.10	2.23	2.37	**2.20**
	PK-Chat（我们的方法）	**0.636/0.532**	0.139/**0.366**	**0.100/0.228/0.128**	**2.73**	**2.26**	**2.40**	**2.43**	1.90
GA-Dialogue（第2部分）	PLATO（Unidirect）	0.106/0.086	0.050/0.137	0.002/0.048/0.003	0.00	0.03	0.03	0.03	0.03
	PLATO	0.342/0.268	**0.105/0.322**	0.022/0.246/0.040	**2.93**	**2.53**	2.50	2.63	2.33
	PK-Chat（我们的方法）	**0.496/0.383**	0.065/0.237	**0.044/0.273/0.074**	2.80	2.43	**2.57**	**2.80**	**2.60**
Persona-Chat	PLATO (Unidirect)	-	0.003/0.010	0.018/0.084/0.028	0.30	0.24	0.20	0.27	0.13
	PLATO	0.231/0.178	0.014/0.053	**0.028/0.138/0.044**	**2.83**	**2.17**	**2.30**	1.97	2.33
	PK-Chat（我们的方法）	**0.257/0.199**	**0.015/0.062**	0.026/0.131/0.042	2.57	1.96	2.17	**2.03**	**2.34**
DailyDialog	PLATO (Unidirect)	0153/0.117	0.042/0.153	-	2.71	1.97	1.67	1.33	1.27
	PLATO	0.388/0.304	**0.055/0.303**	-	2.57	2.33	2.10	2.07	1.90
	PK-Chat（我们的方法）	**0.416/0.329**	0.049/0.282	-	**2.77**	**2.71**	**2.53**	**2.63**	**2.41**

表 1：与基线的比较。

我们抽取了部分数据，最终GA-Dialogue包含1,000个对话场景和8,219轮对话，平均每个场景有**8.21** 轮对话。

3. 实验

在本节中，我们评估对话系统模型的自动评估结果和人工评估结果。本节详细介绍了实验设置和评估结果中使用的基准数据集与评估指标。

3.1. 实验设置

在本小节中，我们简要介绍所选用的基准数据集、基线和指标，以对模型进行实验。

基准数据集 我们选择 Persona-Chat [20] 和 DailyDia- log [21] 作为通用基准数据集，并构建了一个基于学术知识图谱的对话基准数据集 GA-Dialogue。

• Persona-Chat 是一个关于人物档案（背景知识）的基于知识的对话数据集。

• DailyDialog 是一个闲聊数据集，包含关于日常生活的高质量人类对话。

• GA-Dialogue（第 1 部分和第 2 部分）：我们将 GA-Dialogue 测试数据集划分为两部分。第一部分（part1）包含 GAKG 知识图谱上的对话数据；第二部分（part2）的对话评估数据来自外部数据集引入的对话数据评估。数据集可在 GitHub 仓库中获取。[2]

基线我们选择 PLATO [1] 和 PLATO（Unidirect）作为基线，因为对于已知模型规模的同等规模模型，PLATO 取得了最先进的结果；同时选择 PLATO（单向）作为基线模型，以分析单向注意力机制对模型最终生成效果的影响。其模型自注意力结构与 GPT [22] 系列一致。

指标 与面向任务的对话系统不同，由于对话具有灵活性，很难通过特定指标评估开放域对话系统的性能。一般而言，开放域对话系统通过客观评估和主观评估进行衡量，本文采用自动评估方法和人工评估方法对各个模型进行比较。

我们选择 BLEU [23]（双语评估替补）、Distinct [24] 和知识 [1] 作为**自动评估指标**，这些指标的数值越高，模型的表现就越好。

• BLEU 用于评估生成任务，其计算方式是衡量生成的回复与标签的n-gram 之间的重合度。本文将n 设为 1 和 2。

• Distinct 用于衡量生成句子的多样性，计算词语中唯一 n-gram 的比例。本文将n 设为 1 和 2。

• 知识用于判断引用的知识是否正确。

对于人工评估方法，人工评估包括 [25], 中所述的五项指标，本文将其用作**人工评估指标**：可读性、相关性、一致性、信息丰富度和自然度。在每个基准中，我们随机选取 500 段生成的对话及其上下文信息作为评估数据，并邀请 20 位地球科学家评估对话性能，并从以上五个方面分别打分，分值范围为 [0,1,2,3] 分。

3.2. 实验结果

在 GA-Dialogue（第1部分）中，PK-Chat 模型在 BLEU、Distinct 和 Knowledge 指标上优于 PLATO 模型；在 GA-Dialogue（第2部分）中，其在 BLEU 和 Knowledge 指标上优于 PLATO 模型和基线模型。PK-Chat 在人工评估指标的全部五个维度上均优于 PLATO 模型，在评估集第一部分的四项指标中排名最高，在第二部分的三项指标中排名最高。因此，自动评估指标和人工评估指标均有所提升。

同样，在 Persona-Chat 数据集中，PK-Chat 模型在 BLEU 和 Distinct 这两项自动评估指标上的表现优于基线模型，但在 Knowledge 指标上略逊于 PLATO 模型。PK-Chat 模型在人工评估指标方面优于 PLATO 模型。对于这部分对话数据集，我们提出的方法并未提升最终的对话生成效果，因为该数据集中的回答依赖于用户任务画像中的知识，而知识部分很少在回答问题时被直接引用。

[2] https://github.com/davendw49/PK-Chat

对于 DailyDialog，本文提出的方法在该数据集上的自动评估指标和人工评估指标均优于基线模型。对于上下文为历史对话的信息，本文模型能够提升各项指标。观察该数据集可知，与 Persona-Chat 相比，对话内容通常围绕同一话题展开，且对话与闲聊上下文之间的连贯性更强，因此模型可以通过指针网络复现先前问题中的词语，从而取得良好的效果。

4. 结论

本文提出了 PK-Chat，这是一种通过统一预训练语言模型和指针生成网络实现学术对话的知识图谱增强模型，旨在与学者开展流畅、自然且富含知识的对话交互。通过结合统一预训练语言模型和指针网络，该模型能够准确引用知识图谱中提及的知识。此外，我们提出了 GA-Dialogue，作为评估对话代理的基准。

5. 参考文献

[1] Siqi Bao、H. He、Fan Wang 和 Hua Wu，《Plato：采用离散潜变量的预训练对话生成模型》，发表于*ACL*，2020年。[2] Alec Radford 和 Karthik Narasimhan，《通过生成式预训练提升语言理解能力》，发表于*ArXiv*，2018年。[3] Yanmeng Wang、Ye Wang、Xingyu Lou、Wenge Rong、Zhenghong Hao 和 Shaojun Wang，《通过知识图谱过滤器改进对话回复生成》，发表于*ICASSP 2021 - 2021 IEEE*声学、语音与信号处理国际会议 *(ICASSP)*，第7423–7427页，2021年。[4]Jens Lehmann、Robert Isele、Max Jakob、Anja Jentzsch、Dimitris Kontokostas、Pablo N Mendes、Sebastian Hellmann、Mohamed Morsey、Patrick Van Kleef、S¨oren Auer 等，《DBpedia——从维基百科中提取的大规模多语言知识库》，发表于语义网，第6卷，第2期，第167–195页，2015年。[5]MS Fabian、Kasneci Gjergji、WEIKUM Gerhard 等，《YAGO：融合WordNet与维基百科的语义知识核心》，发表于第*16*届国际万维网大会, *WWW*，2007年，第697–706页。[6]Shiquan Yang、Rui Zhang 和 Sarah Monazam Erfani，《GraphDialog：将图知识融入端到端面向任务的对话系统》，发表于*EMNLP*，2020年。[7] Yu Sun、Shuohuan Wang、Yukun Li、Shikun Feng、Xuyi Chen、Han Zhang、Xin Tian、Danxiang Zhu、Hao Tian 和 Hua Wu，《ERNIE：通过知识整合增强表示》，发表于*ArXiv*，第abs/1904.09223卷，2019年。[8] Lisong Qiu、Juntao Li、Wei Bi、Dongyan Zhao 和 Rui Yan，《训练样本之间是否相关？通过多个参考答案学习生成对话回复》，发表于*ACL*，2019年。

[9] Siqi Bao、H. He、Fan Wang、Hua Wu、Haifeng Wang、Wen- quan Wu、Zhen Guo、Zhibin Liu 和 Xinchao Xu，《Plato- 2：通过课程学习构建开放领域聊天机器人》，发表于*FINDINGS*，2021年。[10] Oriol Vinyals、Meire Fortunato 和 Navdeep Jaitly，《指针网络》，发表于*NIPS*，2015年。[11] A. See、Peter J. Liu 和 Christopher D. Manning，《直奔主题：采用指针生成网络进行摘要生成》，发表于*ArXiv*，第abs/1704.04368卷，2017年。[12] Fei Sun、Peng Jiang、Hanxiao Sun、Changhua Pei、Wenwu Ou 和 Xiaobo Wang，《用于商品标题摘要生成的多源指针网络》，发表于第*27*届*ACM*国际信息与知识管理会议论文集，2018年。[13] Cheng Deng、Yuting Jia、Hui Xu、Chong Zhang、Jingyao Tang、Luoyi Fu、Weinan Zhang、Haisong Zhang、Xinbing Wang 和 Chenghu Zhou，《GAKG：多模态地球科学学术知识图谱》，发表于第*30*届*ACM*国际信息会议论文集 & 知识管理，2021年。[14] Li Dong、Nan Yang、Wenhui Wang、Furu Wei、Xiaodong Liu、Yu Wang、Jianfeng Gao、Ming Zhou 和 Hsiao-Wuen Hon，《面向自然语言理解与生成的统一语言模型预训练》，2019年。[15] Juan Enrique Ramos，《使用TF-IDF确定文档查询中的词语相关性》，2003年。[16] Rada Mihalcea 和 Paul Tarau，《TextRank：为文本构建秩序》，发表于*EMNLP*，2004年。[17] Zhiheng Huang、Wei Xu 和 Kai Yu，《用于序列标注的双向LSTM-CRF模型》，发表于*ArXiv*，第abs/1508 01991卷，2015年。。[18] Wenquan Wu、Zhen Guo、Xiangyang Zhou、Hua Wu、Xiyuan Zhang、Rongzhong Lian 和 Haifeng Wang，《通过明确的对话目标实现主动式人机对话》，发表于*ACL*，2019年。[19] Zeming Liu、Haifeng Wang、Zheng-Yu Niu、Hua Wu、Wanxi- ang Che 和 Ting Liu，《面向多类型对话的对话式推荐》，发表于*ACL*，2020年。[20]Saizheng Zhang、Emily Dinan、Jack Urbanek、Arthur D. Szlam、Douwe Kiela 和 Jason Weston，《个性化对话智能体：我有一只狗，你也养宠物吗？》，发表于*ACL*，2018年。[21] Yanran Li、Hui Su、Xiaoyu Shen、Wenjie Li、Ziqiang Cao 和 Shuzi Niu，《DailyDialog：人工标注的多轮对话数据集》，发表于*IJCNLP*，2017年。[22] Alec Radford、Jeff Wu、Rewon Child、David Luan、Dario Amodei 和 Ilya Sutskever，《语言模型是无监督的多任务学习者》，2019年。[23] Boxing Chen 和 Colin Cherry，《句子级BLEU平滑技术的系统比较》，发表于*WMT@ACL*，2014年。[24] Jiwei Li、Michel Galley、Chris Brockett、Jianfeng Gao 和 William B. Dolan，《面向神经对话模型的促进多样性的目标函数》，发表于*NAACL*，2016年。[25] Hongru Liang 和 Huaqing Li，《迈向聊天机器人人工评估的标准准则：综述》，发表于*ArXiv*，第abs/2105.11197卷，2021年。