arXiv:2305.00783v1 [cs.IR] 1 May 2023

面向对话推荐的显式知识图谱推理

XUHUI REN，昆士兰大学，澳大利亚TONG CHEN，昆士兰大学，澳大利亚QUOC VIET HUNG NGUYEN，格里菲斯大学，澳大利亚LIZHEN CUI，山东大学，中国ZI HUANG，昆士兰大学，澳大利亚HONGZHI YIN*，昆士兰大学，澳大利亚

传统推荐系统完全基于历史交互记录估计用户对物品的偏好，因此无法捕捉细粒度且动态变化的用户兴趣，并使用户只能被动地接受推荐。近期的对话式推荐系统（CRSs）通过让推荐系统与用户进行交互，并通过一系列澄清问题获取其当前偏好，从而应对这些局限。尽管对话式推荐系统取得了进展，现有解决方案在以下两个方面仍远不能令人满意：1）当前的对话式推荐系统通常要求每位用户在获得最终推荐之前回答大量澄清问题，这会损害用户体验；2）明确提及的属性与物品的学习到的表示之间存在语义鸿沟。

为解决这些不足，我们引入知识图谱（KG）作为辅助信息，以理解和推理用户偏好，并提出一种新的对话推荐系统（CRS）框架，即**K**nowledge**E**nhanced **C**onversational**R**easoning（KECR）系统。用户可以通过属性级和物品级表达来体现其偏好，KECR 将知识图谱中的结构化知识嵌入其中，从而弥合这两个层级之间的语义鸿沟。同时，KECR 利用知识图谱中的连通性，对用户需求进行显式推理，使模型较少依赖用户对澄清问题的反馈。KECR 能够找到突出的推理链，使推荐具有可解释性和更充分的依据，同时让对话过程更加顺畅，从而提升用户体验和对话式推荐准确率。在两个真实世界数据集上进行的大量实验表明，无论在自动评估还是人工判断方面，我们的方法均优于最先进基线方法。

附加关键词与短语：对话式推荐、知识图谱、偏好挖掘

ACM参考文献格式：
Xuhui Ren、Tong Chen、Quoc Viet Hung Nguyen、Lizhen Cui、Zi Huang 和 Hongzhi Yin。2023年。面向对话式推荐的显式知识图推理。*ACM*智能系统技术汇刊第00卷第0期，第000号文章（2023年），19 页。
https://doi.org/10.1145/nnnnnnn.nnnnnnn

1 引言

近年来，对话式推荐系统（CRSs）因能够通过与用户进行类人对话，提供有说服力且可解释的推荐结果，受到了学术界和业界的广泛关注 [20, 24, 31, 47]。不同于通过分析用户历史记录中的用户偏好来生成推荐结果的传统推荐系统

*通讯作者。

作者地址：Xuhui Ren，x.ren@uq.edu.au，昆士兰大学，澳大利亚昆士兰州布里斯班，4072；Tong Chen，tong.chen@uq.edu.au，昆士兰大学，澳大利亚昆士兰州布里斯班，4072；Quoc Viet Hung Nguyen，henry.nguyen@griffith.edu.au，格里菲斯大学，澳大利亚昆士兰州黄金海岸，4215；Lizhen Cui，clz@sdu.edu.cn，山东大学，中国山东省济南市，250100；Zi Huang，huang@itee.uq.edu.au，昆士兰大学，澳大利亚昆士兰州布里斯班，4072；Hongzhi Yin，h.yin1@uq.edu.au，昆士兰大学，澳大利亚昆士兰州布里斯班，4072。

2023年. 2157-6904/2023/0-ART000 $
15.00https://doi.org/10.1145/nnnnnnn.nnnnnnn

表 1. 电影推荐对话示例。提及的物品和属性分别以蓝色和红色标记。

	用户：嗨，我想要一些电影推荐。系统：你喜欢什么类型的电影？用户：我喜欢恐怖电影，类似于安娜贝尔。我从来不知道一个娃娃竟然能这么吓人。系统：《死寂》可能适合你！这是一部恐怖电影，也能让你一窥温子仁早期的作品。用户：真的吗？我想试试看！

在交互过程中，对话式推荐系统会主动提问，帮助用户在对话期间明确阐述其最新需求，从而实现动态且可解释的推荐。

对话推荐系统的一般框架由对话组件（DC）和推荐组件（RC）组成 [10]。DC 的职责是生成澄清问题和回复，以推进对话。澄清问题以“系统提问-用户回答”（SAUA）的方式，引导用户表达对特定属性类型的偏好 [52]。RC 从对话话语中提取上下文信息，并在置信度较高时推荐合适的物品，以满足用户的偏好。近期，已有多种对话推荐系统被提出，以改善与用户的交互并追求高质量的推荐结果 [20, 24, 31, 47, 52, 55]。

尽管现有对话推荐系统相较于传统推荐系统已取得明显进步，但对话推荐系统的两个内在问题仍阻碍着其实用性。首先，当前对话推荐系统严重依赖用户对澄清问题的回复，以及时获取属性级需求。然而，现实应用中庞大的属性池会导致系统尝试提出大量澄清问题，从而损害用户体验[22] ，因为用户在收到最终推荐结果之前，需要回答一长串问题 [30]。其次，这种 SAUA 交互模式容易在明确的属性级和物品级用户偏好之间造成语义鸿沟 [55]。用户同时在这两个层面表达偏好并不少见，但 SAUA 模式只能捕捉话语中出现的表层关键词，缺乏用于融合属性级和物品级表达、从而更好地理解用户兴趣的补充上下文信息。如表1所示，用户在寻找类似《安娜贝尔》的恐怖电影，其需求通过属性级表达“恐怖”和物品级表达“安娜贝尔”来体现。理想情况下，如果对话推荐系统能够充分利用话语上下文，就可以自然地推导出令人信服的推荐并给出合理解释，例如该示例中的“恐怖电影，也是了解温子仁早期作品的一个窗口”。然而，当代对话推荐系统采用的直接关键词提取方法，无法理解连接“恐怖”和“安娜贝尔”的深层语义，更不用说将二者融合以生成准确推荐。因此，需要一种有效方案来弥合理解用户话语时产生的语义鸿沟。

近期的一些对话式推荐系统将辅助知识图谱（KG）作为补充资源，用于分析物品级和属性级的用户偏好 [4, 9, 32, 51]。然而，现有工作仅以隐式方式利用图结构知识，即通过图神经网络等方法 [34]将知识提炼为用户偏好的潜在表示，这使知识图谱无法发挥显式推理的优势。事实上，知识图谱固有的图结构能够自然地关联物品级和属性级偏好，从而促进对用户需求的显式推理 [4, 15], , 为对话控制器和推荐系统提供更高效的协作方式。从对话控制器的角度来看，推理过程能够以更强的合理性实现更流畅的响应生成。对话策略可以遵循推理流程，主动探索用户兴趣、通过信息丰富的实体进行聊天，并提供附有忠实解释的推荐结果 [26]。

从推荐系统的角度来看，对知识图谱进行推理可以揭示用户与物品之间的联系，从而帮助全面理解用户偏好。额外的连通信息能够提供支持可解释推荐的证据链，也有助于解决推荐过程中的冷启动问题 [33, 42]。

本文提出了一种用于对话推荐系统（CRS）的**知**识**增**强**对话式推**理（KECR）方法，在知识图谱上进行显式推理。本文的核心假设是，在知识图谱上进行显式推理过程能够更好地发挥对话推荐系统的优势，使其具备合理性和可解释性。准确且合理的图推理过程通常需要学习实体嵌入和上下文嵌入。因此，我们引入基于物品的知识图谱（即 DBpedia[1]）来建模物品/属性实体的语义嵌入，并利用预训练语言模型学习上下文嵌入。由于这两种嵌入来自两个不同的嵌入空间，我们进一步采用互信息估计 [11] ，通过在给定对话中的话语-实体共现时，促使两个嵌入空间中的词元嵌入更加接近，从而优化嵌入。这些经过优化的嵌入编码了全面的上下文信息和用户偏好，构成推理模块的输入。推理模块在知识图谱上进行实体选择，从所提及的物品和/或属性出发，寻找通往合适推荐结果的显著路径，并构建推理流程以引导系统生成回复。在这种显式图推理方式的监督下，KECR 从推理流程中选择最相关的实体，并利用预训练语言模型生成类人的回复，从而保证对话内容的连贯性并提高推荐可解释性 [43]。

据我们所知，鲜有对话推荐系统方法能够在知识图谱上进行显式推理，以找到合适的推荐结果及解释。我们提出的 KECR 同时利用结构化知识弥合物品级与属性级偏好表达之间的语义鸿沟，并借助图连通性推断证据链，以支持可解释推荐。最后，我们在两个真实世界数据集上进行了大量实验，以验证我们的方法在推荐准确率和生成的对话质量方面的有效性。

2 相关工作

2.1 知识图谱推理

在知识图谱（KG）上进行显式推理已被证明是检索用户所需物品或答案的有效方法 [8, 28]。先前的研究主要聚焦于在知识图谱上进行多跳推理，以支持问答任务。研究者通过实体图或概念网络扩充查询，以增强其语义表示，再将其输入数据库，从而实现基于相似度的检索 [38, 46]。受物品预测方面优异表现的启发，一些推荐系统采用知识图谱嵌入技术，在推荐过程中改进物品嵌入 [4, 30, 49, 55]。然而，这类方法无法显式利用图中的连接信息，因此会损失可解释性。

为解决这一问题，研究人员提出了几种基于路径的方法。这些方法旨在通过知识图谱 [13, 56] 中实体之间的连接，探索用户与推荐物品之间的重要路径。然而，这些方法缺乏用于获取用户需求的交互式方法，并且其推理过程局限于预定义的元路径，无法根据用户的新输入进行动态优化 [42]。因此，这些方法的性能在很大程度上依赖于用于元路径工程的额外领域知识，而这一过程需要耗费大量人力。

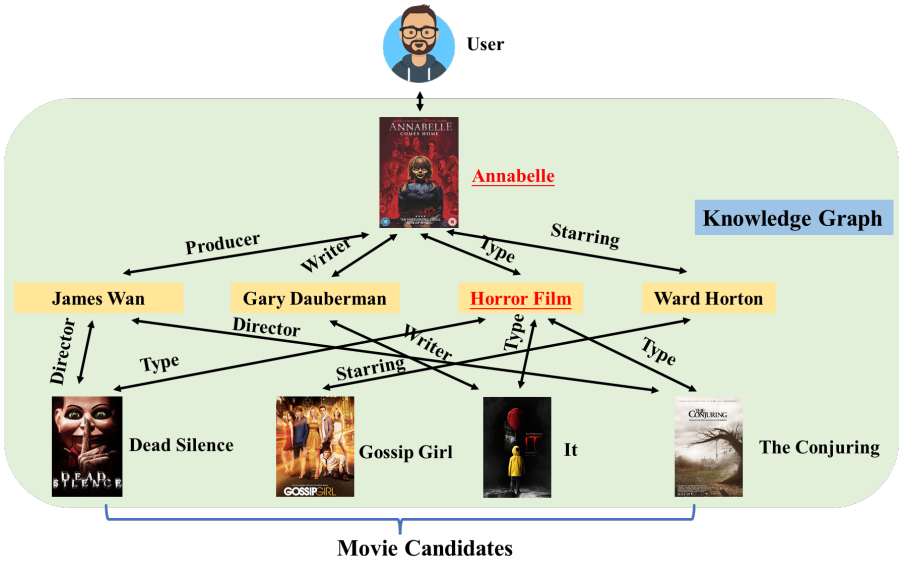

图1. 电影领域中知识图谱内连接信息的示意图。实体之间的实线表示它们的关系，而红色标记的带下划线实体表示用户在对话过程中提及的内容。

2.2 对话式推荐

对话式推荐系统已成为一种颇具吸引力的方法，可弥合用户与系统之间的交互鸿沟，以可解释且准确的推荐满足用户的实时需求。这一新兴研究主题源自面向任务的对话系统，后者通过多轮对话帮助用户完成与推荐相关的任务 [30, 39]。传统的对话式推荐系统遵循 SAUA 模式 [52], ，其中对话控制器会围绕预定义属性提出一系列澄清问题，以收集用户的显式偏好，并采用基于检索/协同过滤（协同过滤）的方法 [14] 推导个性化推荐结果。这类方法的主要局限在于，现实应用场景中包含大量可用于构造澄清问题的候选属性。因此，用户可能需要回答许多澄清问题才能获得最终推荐结果，这会严重损害用户体验。此外，这些方法中的对话行为和内容受到严格限制。用户与对话式推荐系统只能围绕一组固定属性上的用户偏好进行交互，而对话式推荐系统则直接呈现推荐结果，不提供任何解释 [25]。因此，这会导致话语理解中的语义鸿沟，尤其是在用户表达其对物品和属性的偏好时。

一些近期方法采用知识图谱（KGs）来丰富对话信息，以弥合理解过程中的语义鸿沟 [4, 9, 15, 19, 32, 43]。例如， [40, 54] 利用物品属性图，将层级信息与推荐和对话生成过程有效结合起来。正如第 1 节所讨论的，大多数沿着这一方向开展的现有工作并未充分发挥知识图谱的优势（例如，学习从知识图谱 [51]中检索出的子图的隐式表示）。我们认为，知识图谱中的连通信息对于理解用户偏好至关重要。对知识图谱进行显式推理，能更好地发挥对话推荐系统的优势。为此，我们设计了一种新颖的对话推荐系统，通过在知识图谱上显式推理用户偏好。这样一来，我们的模型便能高效、准确地学习用户偏好，并为响应生成提供合理引导。

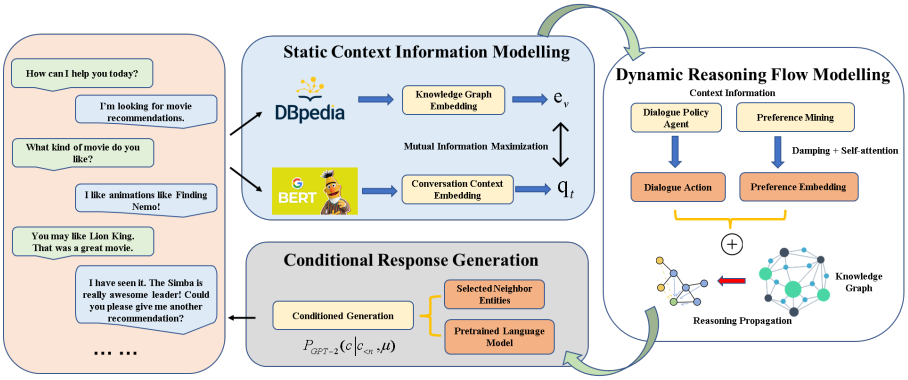

图 2. KECR 的整体工作流程。KECR 由三个关键组件组成：静态上下文信息建模、动态推理流建模和条件响应生成。

3 预备知识

对话式推荐目前是一个新兴的研究课题，已从多个角度引发了探索 [19, 21, 30, 39]。本研究沿用对话推荐系统的基本设定 [39]，同时进行了一些调整，以提升其在现实世界中的适用性。在对话过程中，对话推荐系统可以通过多轮连贯的话语与用户互动，以了解用户实时的偏好。系统根据收集到的偏好推断合适的推荐结果，满足用户需求。对话会持续进行，直到用户接受推荐结果或离开。本文指出，在知识图谱上进行推理能够更好地利用图的结构信息，生成合理且可解释的推荐结果。以表 1 中的电影推荐示例为例，用户想要一部与其看过的 恐怖电影《安娜贝尔》相似的电影。如图 1 所示，这些上下文信息有助于在知识图谱上生成通往潜在推荐结果 《死寂》的推理路径，也有助于推断用户可能偏好该推荐结果的理由：其导演风格与温子仁有关。推理过程揭示了推荐物品背后的原因，使其区别于其他候选项。因此，我们在对话推荐系统的设定中融入推理功能，使其具备可解释性。同时，对话控制器可以利用推理路径生成合理的劝说内容，使系统对话更具吸引力，也更容易被用户接受。

不失一般性，我们将由若干交互轮次组成的对话记作 $\mathrm{X} = \{x_t\}_{t=1}^{\phi}$，其中每个交互轮次 x_t 指系统与用户之间的一对响应话语，而 ϕ 表示对话轮次的数量。为便于推理过程，我们引入一个辅助知识图谱 $\mathrm{G} = (\mathrm{V}, \mathrm{R})$，其中 V 表示实体集，R 表示关系集。物品及其相关属性均表示为知识图谱中的节点（即实体）。每个物品实体通过双向关系与相应的属性实体相连，例如 安娜贝尔 $\overset{Type}{\Longleftrightarrow}$ $Horror\ Film$。在每个对话轮次 t中，系统会选择一部分邻域实体 $v \in \mathrm{V}$，以增强响应生成；这可以视为在知识图谱上的推理传播过程。其目的是优化推理路径，以保持对话的参与度和语义合理性，生成响应话语，并最终向用户推荐物品。

4 方法

本节介绍我们提出的知识增强对话推理（KECR）方法。如图 2所示，KECR主要由三个组件构成：（1）静态

上下文信息建模，旨在将静态话语和知识图谱嵌入为潜在表示；（2）动态推理流建模，用于提取即时上下文信息，以估计用户偏好并预测下一步响应动作，随后在知识图谱上进行推理，为下游任务选择合适的实体；（3）条件响应生成，根据选定实体生成类人回复。以下小节将详细介绍各组件的设计。

4.1 静态上下文信息建模

如第 1 节所示，用户偏好的多样化表达（即物品级和属性级表达）使得难以理解用户话语中蕴含的潜在兴趣，从而妨碍对话推荐系统推导出准确推荐和合适的对话响应。本文从两个角度着手解决这一问题，以改进对此类上下文信息的学习。首先，我们引入知识图谱来丰富用户表达的语义，从而揭示物品级与属性级用户偏好之间的关联。然后，采用预训练语言模型来学习对话上下文的语义表示。

4.1.1 知识图谱嵌入。为了为我们的对话推荐系统构建知识图谱，我们遵循 [4, 55]从 DBpedia 重建一个仅包含语料库中出现的项目实体的子图。原始 DBpedia 仅包含从物品指向其对应属性的有向链接，这不足以在推荐上下文中对知识图谱进行嵌入和推理。因此，我们将项目—属性关系扩展为双向关系，并添加从通用类别（例如电影类型和发行日期）指向其取值的新链接，以补充知识图谱中的信息。

由于实体相互连接的邻居能够反映其内在属性，近年来，基于图卷积网络（GCN）的研究方法在聚合邻域数据以增强知识图谱（KG）中学习到的实体嵌入方面，展现出了最先进的效果 [41, 45, 53]。为了对这些关系信息进行建模，我们采用关系图卷积网络（R-GCN） [35]，该网络通过关系特定权重矩阵对 GCN 进行泛化，从而以更精细的粒度学习实体表示。在第 $(l+1)$ 层，每个实体 $v \in \mathrm{V}$ 的嵌入通过从其一跳邻居传播信息来学习：

$$\mathbf{e}_v^{l+1} = \sigma\Big(\sum_{r\in R}\sum_{v'\in\mathcal{N}_r(v)}\frac{1}{z_v^r}\mathbf{W}_r^l\mathbf{e}_{v'}^l + \mathbf{W}_0^l\mathbf{e}_v^l\Big), \tag{1}$$

其中，σ 表示Sigmoid函数，$\mathrm{N}_r(v)$表示关系 $r \in \mathrm{R}$下实体 v 的邻居实体集，z_v^r为归一化因子，$\mathbf{W}_r^l$ 和$\mathbf{W}_0^l$ 分别表示用于整合第 l层关系特定邻居和自环的可学习权重矩阵。为方便符号表示，我们将最后一层的实体嵌入记为$\mathbf{e}_v$，并将其用于后续计算。

4.1.2 对话上下文嵌入。 在对话推荐过程中，系统会与用户交互，从对话上下文中获取有关用户实时偏好的必要信息，并生成高质量推荐。上下文嵌入的学习会影响对话推荐系统对用户偏好的理解。近期，在开放域对话系统中采用大型预训练语言模型（例如 BERT [7]和 GPT-2 [2]）的研究，在对话上下文建模方面取得了显著进展[50], ，展现出利用大型预训练语言模型进行对话式推荐的潜力。

为此，我们采用 BERT（一种预训练多层 Transformer）对对话话语进行嵌入。在每个对话轮次中，系统与用户在 $x_t \in \mathrm{X}$之间的对话话语拼接后（作为词元 ID 序列）输入 BERT，以获取其潜在

嵌入 $\mathbf{x}_t$。为增强与对话历史的上下文联系，我们构建了一个门控循环单元（GRU） [5]，以处理长期序列依赖关系。第 t 轮的上下文嵌入通过以下方式获得：

$$\mathbf{q}_t = GRU(\mathbf{q}_{t-1}, \mathbf{x}_t). \tag{2}$$

除了上下文嵌入 $\mathbf{q}_t$ 之外，对话中提及的实体对于理解用户的偏好尤为重要。为了在对话过程中识别这些实体，我们使用 Spacy[1] 对用户话语的词形还原形式进行模糊匹配，并将其映射到知识图谱（KG）中。在第 t 轮中，我们将所有先前 t 轮中实体的知识图谱嵌入存储为对话信念状态，记作 $\mathbf{D}_t = [\mathbf{e}^{v_1}, \mathbf{e}^{v_2}, \cdots, \mathbf{e}_{v_E}]$，其中 E 个实体按时间顺序排列。

4.1.3 通过互信息估计学习嵌入。我们在此介绍如何联合学习知识图谱与对话上下文嵌入。给定构建好的知识图谱和完整的对话 X，可以选择分别学习每种类型的嵌入。然而，由于知识图谱实体和对话上下文的表示是从两个不同的嵌入空间中生成的，这种做法会加剧语义差异。在一个话语中，由于被提及的实体 v 具有丰富的信息，并且与对话上下文高度交织，因此我们利用互信息（MI）最大化技巧 [37, 48, 55]，对高度相关的知识图谱嵌入和对话嵌入进行对齐与融合。其核心思想是计算两个相互关联变量之间的互信息，即在我们的案例中，共同出现的实体 $v \in \mathrm{V}$ 和话语 $x_t \in \mathrm{X}$ 之间的互信息：

$$MI(v, x_t) = D_{KL}(p(v, x_t) \| p(v)p(x_t)), \tag{3}$$

其中，D_{KL} 表示联合分布 $p(v, x_t)$ 与边缘分布的乘积 $p(v)p(x_t)$ 之间的 Kullback-Leibler 散度。

鉴于在实践中精确计算互信息（MI）难以实现，我们采用一种神经网络方法，利用 Jensen-Shannon 散度 [11], 估计 MI，该方法可表示为以下二元交叉熵（BCE）形式 L_{MI}：

$$\begin{aligned} L_{MI} &= \mathbb{E}_P[\log(g(\mathbf{e}_{v^+}, \mathbf{q}_t))] + \mathbb{E}_N[\log(1 - g(\mathbf{e}_{v^-}, \mathbf{q}_t))] \\ &\leq MI(v, x_t) \end{aligned} \tag{4}$$

其中，$\mathbb{E}_P$ 和 $\mathbb{E}_N$ 分别表示对所有正样本和负样本的期望。$g(\cdot, \cdot)$ 是一个神经分类器，其输入为一个实体和一条话语的嵌入向量的拼接，并计算取值范围为 $[0, 1]$的概率。在 KECR 中，对于每个由共现话语和其中提及的实体组成的正样本（v^+, x_t），我们通过随机抽取话语 x_t 中未出现的实体，为其配对四个负样本（v^-, x_t）。

通过最大化 L_{MI}，我们实际上可以提高 MI 的下界。在这一静态上下文信息建模过程中，通过校准并融合知识图谱嵌入与公式（2）中 GRU 编码器的互信息，它有助于我们有效地预训练二者。这使 $\mathbf{e}_v$ 和 $\mathbf{q}_t$ 生成的表示具有更强的表达能力，并将用于后续的推理和推荐任务中，且会在其中进一步微调。

4.2 动态推理流程建模

基于从知识图谱和话语中提取的静态信息，我们需要动态理解实时用户偏好，并在知识图谱上进行推理，以找到合适的实体来推进对话和/或生成准确的推荐。影响推理过程的因素主要有两个：模型即将执行的对话动作（例如查询或推荐），以及从对话中挖掘出的用户偏好。

[1]https://spacy.io/

生成的对话动作有助于校正推理流程，使其与对话上下文保持连贯。同时，用户偏好有助于选择最符合用户需求的实体。本节将详细说明如何计算这两个因素，以及如何利用它们在知识图谱上进行显式推理。

4.2.1 对话策略智能体。对话策略智能体根据当前对话上下文决定应执行哪种对话动作。以往的对话推荐系统通常从基于 SAUA 的交互方案角度定义对话动作，其中每个动作都被定义为一个针对特定属性的是非问题，例如："你喜欢动作电影吗？"正如近期研究所指出的，[18, 30], 这会导致训练高性能策略智能体所需的动作空间不必要地庞大，而且获取用户偏好的效率较低。因此，我们将动作空间缩减为三种动作：查询、推荐和闲聊；推理过程则进一步决定将采用哪个相关属性（即知识图谱实体）来组织对话回复。

受面向任务的对话系统相关先前研究的启发，这些研究根据对话上下文的摘要来估计系统动作 [25, 44], ，我们使用多层感知机分类器训练策略智能体，以决定每个对话轮次中的对话动作。由于预训练的对话上下文编码器具有足够强的表达能力，我们仅将对话嵌入作为策略智能体的输入：

$$\mathbf{a}_t = \text{softmax}(\mathbf{W}_1\text{ReLU}(\mathbf{W}_2\mathbf{q}_t + b_2) + b_1), \tag{5}$$

其中，$\mathbf{a}_t$表示三种对话动作上的概率分布，$\mathbf{W}_1, \mathbf{W}_2, b_1, b_2$用于通过可学习的权重和偏置参数化策略智能体。策略智能体通过最小化以下交叉熵损失进行学习：

$$L_a = -\sum_{\forall i} a^*_{t,i} \log(a_{t,i}), \tag{6}$$

其中，$a^*_{t,\ i}$和$a_{t,\ i}$分别表示真实值和预测值中的第 i个元素。

4.2.2 偏好挖掘。如第 4.1.2 节所述，在每一轮对话中，对话中提及的信息丰富的实体都会存储在 $\mathbf{D}_t$ 中。直观而言，这些信息丰富的实体的编码能够充分反映用户偏好。我们不只是简单地对这些向量取平均值，而是进一步从上下文和时间两个角度考虑其边际效应。

上下文感知需要识别输入上下文中的主导特征，而不是将所有实体一视同仁。因此，我们采用一种简化的自注意力机制 [23] 来计算上下文级用户偏好表示：

$$\mathbf{u}_{cont} = \mathbf{D}_t \cdot \text{softmax}(\mathbf{W}_3\tanh(\mathbf{W}_4\mathbf{D}_t)) \tag{7}$$

其中，$\mathbf{W}_3$ 和$\mathbf{W}_4$ 是权重矩阵。

时间边际效应来自对话期间的话题/兴趣转变。用户可能改变主意，并在一次对话中请求不同的推荐结果。因此，我们采用阻尼因子 $\boldsymbol{\gamma} = [\gamma_1, \gamma_2, \cdots \ \gamma_E]$来控制对话历史的信息影响强度，并将时间层面的用户偏好表示为：

$$\mathbf{u}_{time} = \mathbf{D}_t\boldsymbol{\gamma}. \tag{8}$$

这样，最终的用户偏好嵌入是$\mathbf{u}_{cont}$和$\mathbf{u}_{time}$之间的均值。 :

$$\mathbf{u}_t = \frac{\mathbf{u}_{cont} + \mathbf{u}_{time}}{2}. \tag{9}$$

4.2.3 基于知识图谱的异构推理。为了在知识图谱上进行显式推理，我们设计了一个异构图推理模块，将对话动作和用户偏好扩展为推理路径，从而为对话生成选择合适的实体，例如选择要查询的属性或识别要推荐的物品。

具体而言，推理过程的起点是对话上一轮中出现的实体 v_{t-1}。如果对话早期阶段的用户话语中未提及任何实体（例如，$t = 1$），则会随机选择一种通用属性类型（例如电影领域中的演员、类型、类型），以提出澄清问题。由于对话式推荐中的话语通常较短，因此很少有话语包含多个实体。如果用户确实在单条话语中提及多个实体，则会随机选择其中一个作为起点。尽管在这种情况下，选择相关性更高的实体更为理想，但这需要借助用户档案或交互历史来进行语义匹配。然而，大多数对话式推荐场景都处于严格的冷启动条件下，每次对话都被视为一次独立会话，且没有关于任何用户的先验知识。

给定起点 v_{t-1}，推理的目标是从其邻居 $v \in \mathrm{N}(v_{t-1})$ 中确定推理路径的下一个实体，并且该实体应与给定的上下文相一致。因此，我们需要计算相关性得分，以评估当前上下文下每个邻居节点的置信度，即用户偏好嵌入 $\mathbf{u}_t$、对话上下文$\mathbf{q}_t$以及对话响应动作 $\mathbf{a}_t$：

$$\begin{aligned} \mathcal{J}(k) &= \sigma(\mathbf{h}_k \mathbf{W}_{proj} \mathbf{h}_c), \\ \mathbf{h}_k &= [\mathbf{e}_{v_{t-1}}; \mathbf{e}_k], \\ \mathbf{h}_c &= [\mathbf{a}_t; \mathbf{u}_t; \mathbf{q}_t], \end{aligned} \tag{10}$$

其中，k 表示索引实体 $v_k \in \mathrm{N}(v_{t-1})$，$\mathbf{e}_v$ 和$\mathbf{e}_k$ 分别表示起始实体和邻居实体的知识图谱嵌入。相关性得分 $\mathrm{J}(k)$表示每个 v_k与起始点 v_{t-1}的相关程度。相关性得分最高的邻居将被选入推理路径。由于这一邻居选择过程可视为对每个 $v_k \in \mathrm{N}(v_{t-1})$进行二元决策，我们通过最小化以下二元交叉熵损失来优化这一过程：

$$L_r^j = -\sum_{v_k \in \mathcal{N}(v_{t-1})} \mathcal{J}(k) \log \mathcal{J}(k) + (1 - \mathcal{J}(k)) \log(1 - \mathcal{J}(k)), \tag{11}$$

其中，损失函数特别以 j为索引。其理由是，当需要执行推荐动作，且物品实体作为 v_{t-1}的一跳邻居被到达时，我们期望系统既能提供推荐，也能说明选择该物品的原因。因此，在选出 v_{t-1}的一跳邻居后，我们提出在 KECR 中从这个选定的邻居实体重复推理过程。推理方式与式(10)类似。这样，系统便能沿知识图谱路径继续推理，检索与物品密切相关的属性，进而生成解释，以增强系统响应的合理性和说服力。同时，这也使第二步推理容易受到第一步结果的影响。因此，我们为第二步推理 λ 附加一个较小的权重 $j = 2$，以避免意外的累积误差。最终的推理损失 L_r 为：

$$L_r = L_r^1 + \lambda L_r^2. \tag{12}$$

4.3 条件响应生成

生成器将选定实体和上下文整合到解码过程中，并生成回复，这可以视为语言生成中的查询扩展问题。鉴于基于变换器的语言模型在将概念扩展为描述性文本方面已取得成功，

算法1： KECR 的训练算法。

输入： 知识图谱 G = (V,R)，训练数据 X
结果： 图嵌入 θ_g、上下文嵌入 θ_c、策略智能体的微调参数 θ_a、推理模块 θ_r

随机初始化 $\theta_g, \theta_c, \theta_a, \theta_r$;
通过最大化公式(4)中的 MIM损失 L_{MI}，对 θ_g 和 θ_c 进行预训练;
对于 $t = 1 \rightarrow |X|$，**执行**
    根据公式(1)，从 G 获取实体嵌入 e_v，并从 X 获取上下文嵌入 q 以及公式(2)，分别获取;
    根据公式(5)预测对话动作 a;
    根据公式（7-9）计算用户偏好表示 u;
    从起始节点出发，在知识图谱（KG）上进行推理，计算相关分数。邻居，依据公式(10);
    根据式（10）进行第二步推理;
    使用公式 (6、11–12) 更新 θ_a 和 θ_r
结束
返回 $\theta_g, \theta_c, \theta_a, \theta_r$

句子 [3, 15, 36]，以及预训练语言生成模型的最先进性能，从头开始训练语言生成模型并无必要。还值得一提的是，我们的创新主要在于通过互信息最大化学习具有表达力的知识图谱和对话表示，以及显式的知识图谱推理。因此，我们采用 GPT-2[29] 在 KECR 中生成下一轮的回复 $y_{t+1} = \{c_1, c_2, \cdots c_N\}$，其由 N个词元组成： $c_n = \text{argmax} P_{\theta_{GPT-2}}(c \mid c_{<n}, \mu)$，其中 μ表示由.....得到的两个实体$\forall c$

前述推理过程，而 θ_{GPT-2} 表示预训练的 GPT-2 模型，用于参数化词元 c的概率计算。生成回复中的第 n 个词元时，GPT-2 会对选定实体 μ 与上下文 x_t的拼接嵌入进行编码，然后使用核采样方法 [2, 12], 依次解码回复中的词元，从而生成语义更丰富的回复。

4.4 训练

我们提出的 KECR 的训练过程包含两个阶段：（1）用于静态上下文信息建模的预训练；以及（2）对话策略智能体和动态推理模块的联合训练。对于第一阶段，训练目标是通过互信息估计，融合图嵌入和上下文嵌入中的互信息。我们通过最大化由二元交叉熵损失 L_{MI} 在第 4.1.3 节中定义的互信息下界，优化每种嵌入的语义空间。对于联合训练阶段，我们首先根据对话上下文推断响应动作。随后，我们结合阻尼效应和自注意力机制，得到用户偏好嵌入。在对话动作、上下文嵌入和用户偏好嵌入的条件下，KECR 在知识图谱上进行推理，以寻找合适的邻居，从而制定下一步响应。通过最小化 L_a 和 L_r之和，优化 KECR 的模型参数。需要注意的是，GPT-2 已经在大规模网络语料库上完成训练和优化，因此我们直接继承原始 GPT-2 模型来解码对话响应。详细的训练过程见算法1。

表2. REDIAL 和 GoRecDial 的统计信息。

		REDIAL	GoRecDial
对话	交互	10006	9125
	#话语	182150	170904
	#电影	6924	3782
KG	#实体	30471	19308
	#关系	12	12
	#三元组	392682	227384

5 实验

我们在两个真实世界数据集上评估 KECR。具体而言，我们旨在回答以下研究问题（RQs）：

RQ1：与当前最先进的对话推荐方法相比，我们提出的 KECR 表现如何?

RQ2: 我们的互信息估计和偏好推理模块真的有效吗？**RQ3:** KECR 如何使对话流程更顺畅，并提供更具说服力的推荐结果?

5.1 数据集

我们在两个公开可用的数据集 REDIAL [20] 和 GoRecDial [16],上进行了实验，这两个数据集采用绿野仙踪范式收集 [17]。对话由通过亚马逊土耳其机器人招募的人工志愿者生成。原始语料库包含许多语法错误和不完整的词元，因此我们在训练前对其进行了人工修正。两个数据集都聚焦于电影推荐领域。REDIAL 包含向导与寻求者之间的自由聊天。向导了解用户偏好，并为寻求者选择合适的推荐。单次对话中至少会提及四部不同的电影。GoRecDial 还提供了寻求者的观影历史。向导与寻求者聊天以了解其偏好，并从给定的五个候选项中推荐一部电影。

为全面模拟真实应用场景，我们通过精确匹配名称，将电影映射到 DBPedia，从而构建知识图谱，并过滤掉不适当的关系。最终，保留 DBPedia 中的演员、导演、时间、类型和主题 关系。除这些关系外，我们还在知识图谱中添加逆关系，以增强属性实体的图嵌入，如第 IV.A.(1) 节所述，从而使项目实体和属性实体拥有足够的邻居用于嵌入学习。我们还创建了归属 关系，用于连接属性与由关系定义的通用说明实体。表 II 展示了预处理后两个数据集及其知识图谱的统计信息。

5.2 实验设置

5.2.1 实现细节。 我们遵循第 IV.D 节介绍的流程，使用 PyTorch 实现系统。我们将每个数据集随机划分为训练集、验证集和测试集，比例为 8 : 1 : 1。为方便起见，图和上下文嵌入的维度均设为 128。RGCN L 的嵌入层设为 1，归一化因子$Z_{v,\ r}$设为 1。公式 (9) 中的阻尼因子设为 0.95。学习率设为 0.001，预训练和联合训练的批次大小分别为 10 和 30。我们采用 Adam 作为优化器，权重衰减设为 0.01。KECR 中使用的预训练语言模型 BERT 和 GPT-2 是

表 3. 两个数据集上所有方法的推荐性能比较，其中最佳性能以粗体标出。相较于所有基线方法的提升在统计上均显著，且 $p < 0.01$。

	REDIAL			GoRecDial	
	R@1（%）	R@10（%）	提升（R@1）	R@1（%）	提升（R@1）
REDIAL	1.93	10.30	+102.59%	69.18	+14.21%
KBRD	3.02	15.73	+29.47%	74.52	+6.03%
KGSF	3.78	16.15	+3.44%	77.36	+2.13%
CRWalker	2.05	11.42	+90.73%	72.83	+8.49%
KECR	**3.91**	**16.49**	-	**79.01**	-

Transformers 工具包中发布的基本类型[2]。KECR 不涉及对预训练语言模型进行微调。因此，在训练过程中，我们冻结 BERT 和 GPT-2 的参数。

5.2.2 基线方法。近年来，对话推荐系统研究逐渐兴起，探索了其在各种场景和设置中的应用。为了验证我们提出的 KECR 的性能，我们选取了几种针对与我们提出的方法相同应用设置的最先进基线方法。基线方法总结如下：

- ReDial：这是一个用于 REDIAL [20] 的基准模型。它由一个基于 RNN 的语言生成模块、一个基于协同过滤的推荐器和一个情感分析模块组成。
- KBRD：这是一种基于知识的对话推荐系统 [4]，能够实现用户偏好知识与生成的推荐结果之间的相互增强。
- KGSF：该方法解决了对话推荐过程中的语义鸿沟问题 [55]。基于用户偏好的知识增强嵌入，推荐组件会生成合适的推荐结果，并将其输入基于 Transformer 的解码器以生成回复。
- CRWalker：该方法将对话式推荐过程中用户偏好的推理过程转化为知识图谱 [25] 上的树状遍历。模型从根节点开始扩展用户偏好推理树，直至叶节点末端。解码器整合推理树，为每个对话轮次生成回复。

尽管近期还有其他对话式推荐系统 [6, 18, 19, 30],，但由于任务设置不同，无法将它们用于比较。例如， [18, 19] 旨在基于偏好估计提出一系列是/否问题，而 [6] 旨在通过强化学习，在对话式推荐过程中学习对话策略。

5.2.3 评估指标。 我们从两个方面评估不同方法的性能：自动评估和人工评估。自动评估包括对推荐准确性和语言生成质量的评估。遵循 [55],，我们采用 Recall@k (R@k) 评估推荐性能，采用 Distinct n-gram (Dist-n) 衡量生成回复的多样性，并采用 BLEU 比较生成回复与真实句子之间的相似度。不同于以往在句子级评估性能的方法，我们在上下文级评估性能，这对于对话场景而言更加全面。

自动评估指标有时可能无法反映生成回复的实际属性 [27]。基于相似度的评估指标（即 BLEU）可能会误导解码器生成

[2]https://github.com/huggingface/transformers

表4. 按 Distinct-n 指标比较所有方法在两个数据集上的响应生成性能，其中最佳性能以粗体标出。此外，我们将 Distinct-n 指标上的次佳性能加下划线。

	REDIAL			GoRecDial		
	Dist-2	Dist-3	Dist-4	Dist-2	Dist-3	Dist-4
ReDial	10.61	13.07	12.40	11.66	13.23	12.61
KBRD	11.38	23.44	30.21	13.46	17.19	24.92
KGSF	13.45	27.53	34.51	14.14	18.66	27.59
CRWalker	**27.24**	**39.61**	**49.57**	**22.63**	**32.36**	**43.12**
KECR	**26.45**	**36.10**	**42.18**	**18.13**	**27.62**	**39.15**

包含更多相似词元的回复，而忽略语法和流畅度。因此，我们遵循[24] 邀请外部人工志愿者对生成回复的 4 个属性进行评分（评分范围为 1-5），包括流畅度、连贯性、信息丰富度和句法。

5.3 性能比较

表 III 和表 IV 展示了我们提出的方法以及基线方法的实验结果[3]。显然，我们提出的 KECR 在推荐性能方面表现最佳，在回复多样性方面表现次优。

推荐有效性。 如表 III 所示，与基于 CF 的 ReDial 相比，大多数基于知识图谱的方法都能取得更好的推荐性能。这主要是因为 ReDial 生成推荐结果时完全依赖训练语料库中的协同信号。采用简单的协同过滤使 ReDial 无法利用辅助信息（例如知识图谱）来提取用户偏好，阻碍了其生成准确推荐，尤其是在稀疏对话场景下。KBRD 提出了一种有效的方法，将知识图谱作为补充信息，通过 RGCN 丰富物品嵌入。这表明利用知识图谱能够提升对话推荐系统的效果。KGSF 使用两个知识图谱，即 ConceptNet 和 DBPedia，融合基于词元和基于物品的语义，从而促进细粒度的用户偏好建模与推荐。然而，这两种基于知识图谱的方法都只关注在对话过程中丰富物品嵌入或词元嵌入。它们无法利用显式的知识图谱连接来推理用户偏好，并缩小推荐候选项的范围。CRWalker 引入了推理模块来生成推荐结果，但忽略了有助于优化推理过程的上下文信息，导致其推荐性能较差。

对话质量。 从响应生成的角度来看，表 IV 对所有方法进行了公平比较，其中 ReDial 的生成性能仍然最差。ReDial 采用基于 RNN 的编码器-解码器架构生成回复，严格遵循从训练语料库中学习到的语言规则。由于缺乏来自知识图谱的辅助信息，该方法无法充分提取对话上下文中的语义，因此难以生成高质量的回复。KBRD 和 KGSF 将来自知识图谱的词汇偏置引入 Transformer 模块，以丰富回复表示。然而，如上文所述，它们的方法主要侧重于在对话过程中丰富物品/词元嵌入。它们无法利用显式的知识图谱连接来论证并解释其推荐结果。CRWalker 在 Dist-n 上取得了最高分。然而，这主要是因为其不准确的推荐预测会进一步误导后续推理过程，并引入无关的词汇偏置污染解码过程，从而导致异常偏高的 Dist-n 分数。

[3]如第 V.A 节所述，GoRecDial 会在对话过程中提供 5 个推荐候选项，因此我们仅评估 GoRecDial 上的 R@1。

表 5. 两个数据集上所有消融方法在 Recall@10、BLEU 和 Distinct-3 指标上的性能比较，其中最佳性能以粗体标出。

	REDIAL		GoRecDial	
	R@10 (%)	Dist-3	R@1 (%)	Dist-3
KECR	**16.49**	36.10	**79.01**	27.62
KECR-M	15.63	37.18	76.52	28.46
KECR-R	7.36	**45.64**	43.82	**48.6**

表 6. 人类对所有方法在采样对话中的流畅度、连贯性和信息丰富度进行评估和句法，wh其中最佳性能以粗体显示。

	流畅度	连贯性	信息丰富度	句法
ReDial	4.1	4.2	3.2	3.5
KBRD	4.2	4.0	4.1	4.1
KGSF	4.1	4.0	4.2	4.1
CRWalker	4.0	4.3	4.3	4.4
KECR	**4.4**	**4.6**	**4.7**	**4.5**

我们提出的 KECR 通过在知识图谱上进行显式推理，解决了基线方法的所有上述缺陷，并在 Dist-n 和召回率方面均取得了优异性能。对话推荐系统的主要目标是为用户推荐合适的物品，这一目标通过 R@K 进行评估；与基线方法相比，KECR 取得了最佳性能。当只能获取有限的偏好信息时，推理过程能够识别知识图谱中的信息丰富路径，以找到合适的推荐结果。除了推荐准确率之外，我们还希望系统生成多样化的回复，而不是像训练语料库中那样生成相似的回复。KECR 中的推理组件能够提供合理的词汇多样性，以扩展实际的语义表示，并促进语言生成的多样化。这些额外的词汇偏置会依次注入大型预训练语言模型，使我们的系统能够基于用户偏好生成忠实解释。

5.4 消融研究

静态上下文信息建模和动态推理流程是我们提出的 KECR 的两个主要组成部分。我们在每个部分中特别引入互信息估计和动态推理模块，以提升基础对话推荐系统的性能。为了验证系统中新提出组件的有效性，我们设计了 KECR 的两个变体：**KECR-M** 和**KECR-R**。KECR-M 保留所有其他组件，但移除互信息估计。KECR-R 保留互信息估计，以融合两个通道嵌入信号，但对推理部分进行了修改。我们用随机选择模块替换推理组件，该模块随机选择起始点的一个邻居来构造下一条回复。它还会进行两步推理，为这一选择生成伪解释。为了展示性能变化，我们使用 BLEU 和 Dist-3 评估对话质量，并使用 R@10/R@1（分别在 REDIAL/GoRecDial 上）评估推荐。

从表 V 中可以看出，与这两个变体相比，我们提出的方法在默认设置下仍保持最佳性能。默认设置下 R@K 得分的提升表明，互信息估计和推理模块都能为寻找目标物品提供更好的指引。与默认设置相比，KECR-M 的性能持续下降，证明了互信息估计的作用。

我们还注意到，与默认设置相比，KECR-R 的 Dist-n 得分更高。这主要是因为随机选择策略在最终解码阶段引入了错误词元，从而提高了基于相似度的 Dist-n 得分。Dist-n 得分的提升也伴随着 BLEU 和 R@K 性能的下降。KECR-R 无法准确识别用户偏好，也无法向用户推荐合适的物品，因此未能完成对话推荐的主要任务。

5.5 人工评估

自动评估指标有时过度依赖 n 元语法特征的相似性，因此无法全面评估生成回复的实际质量，例如流畅度、连贯性、信息丰富度和句法。然而，现实世界中的应用更关注生成句子的实际质量，而非各种评估指标。因此，我们遵循 [24]，招募了十名外部志愿者，从四个方面对生成的对话进行评分（评分范围为 1-5）：流畅度、连贯性、信息丰富度和句法。分数越高，表明志愿者对语言质量某一特定方面的评价一致性越高。我们从 REDIAL 中抽取了 20 段对话，分别与我们提出的方法及不同的基线方法进行交互。

表 VI 展示了从人工志愿者收集到的盲评结果。KGSF、KBRD 和 CRWalker 在四个评估方面均获得了令人满意的分数，这主要得益于采用了基于 Transformer 的语言模型以及来自知识图谱的辅助信息。ReDial 沿袭了基于 RNN 的语言模型的特性，即在解码时倾向于模仿训练语料库中出现的对话行为，因此在流畅度和连贯性方面表现良好。最后，我们提出的 KECR 始终优于所有基线方法。KECR 能够在知识图谱上进行推理，提供信息丰富的实体作为指导，从而增强生成回复的连贯性和信息丰富度。此外，它还受益于强大的预训练语言模型，该模型在海量开放网络文本上训练而成。预训练语言模型会扩展推理过程中获得的关键查询，以构建回复，从而确保生成回复的流畅度和句法。

5.6 定性分析

在本部分中，我们将通过一项定性研究说明 KECR 如何提升生成回复的质量，并生成带有令人信服的描述的可解释推荐。

图 3 展示了我们的人类志愿者与所提出的 KECR 系统之间的一段对话。志愿者与系统互动，询问周末晚上的电影推荐。对话始于志愿者的问候，以激活服务。KECR 首先将对话动作识别为“查询”，并选择“类型”来询问用户偏好。随后，用户依次表达了自己的偏好，分别提及物品实体《火星救援》和属性实体“超级英雄”。策略智能体为这两个对话轮次生成的对话动作均为“推荐”。KECR 开始在知识图谱上进行推理，以找到一部具有相同属性、适合推荐的电影，并生成相应的理由（即第二步推理过程）。根据选定实体，我们基于 GPT-2 的解码器生成类似人类且有说服力的回复，以推荐该物品。最后，对话中没有出现新提及的实体，用户接受了推荐。KECR 转而执行“聊天”动作，并对用户说“再见”。

对话过程中有一个有趣的回复：KECR 在第三轮对话中提到“我的兄弟”，以增强推荐的置信度。这是预训练语言模型带来的附带优势，使我们的系统更容易生成类人回复。



图3. 我们的 KECR（向导）与一位真实用户（寻求者）之间的对话示例。红色字体标示了推理过程中的对话动作和选定实体。

6 结论与未来工作

本文提出了一种面向对话推荐系统的新型知识增强对话推理方法。首先，我们利用知识图谱中的辅助结构化知识，弥合属性级表示与项目级表示之间的语义鸿沟，并采用互信息最大化来对齐上下文与知识图谱的语义空间。在对齐后的语义表示基础上，我们对知识图谱进行显式推理，寻找突出的推理链，以提升推荐和对话生成的效果。在两个真实世界数据集上进行的大量实验表明，我们提出的系统优于最先进基线方法。

关于未来的工作，我们将考虑引入多模态外部资源（例如视频、人口统计信息），以丰富对话推荐系统的学习到的表示。此外，我们将探索在真实对话场景中实现我们的系统，并加入更多对话行为（例如闲聊、票务预订、电影安排），以满足用户的多样化需求。最后，在边缘设备上部署对话式推荐系统时，降低计算成本并保护用户隐私将是一个高度相关的研究主题。

参考文献

[1] Christian Bizer、Jens Lehmann、Georgi Kobilarov、Sören Auer、Christian Becker、Richard Cyganiak 和 Sebastian Hellmann。2009年。DBpedia——数据网络的结晶点。《网络语义学期刊》7，3（2009年），154–165。[2] Paweł Budzianowski 和 Ivan Vulić。2019年。你好，这是 GPT-2——我能为你做什么？迈向预训练语言模型在面向任务的对话系统中的应用。载于《神经生成与翻译研讨会》第 3 届会议论文集。15–22。[3] Jifan Chen、Shih-Ting Lin 和 Greg Durrett。2019年。通过推理链进行多跳问答。载于 arXiv 预印本 arXiv:1910.02610。[4] Qibin Chen、Junyang Lin、Yichang Zhang、Ming Ding、Yukuo Cen、Hongxia Yang 和 Jie Tang。2019年。迈向基于知识的推荐对话系统。载于 EMNLP-IJCNLP。1803–1813。[5] Kyunghyun Cho、Bart van Merriënboer、Caglar Gulcehre、Dzmitry Bahdanau、Fethi Bougares、Holger Schwenk 和 Yoshua Bengio。2014年。使用 RNN 编码器–解码器学习用于统计机器翻译的短语表示。载于 EMNLP。1724–1734。[6] Yang Deng、Yaliang Li、Fei Sun、Bolin Ding 和 Wai Lam。2021年。通过基于图的强化学习进行统一对话式推荐策略学习。1431–1441。[7] Jacob Devlin、Ming-Wei Chang、Kenton Lee 和 Kristina Toutanova。2019 年。BERT：面向语言理解的深度双向 Transformer 预训练。载于 NAACL。4171–4186。[8] Yanlin Feng、Xinyue Chen、Bill Yuchen Lin、Peifeng Wang、Jun Yan 和 Xiang Ren。2020年。用于知识感知问答的可扩展多跳关系推理。载于 EMNLP。1295–1309。[9] Zuohui Fu、Yikun Xian、Yaxin Zhu、Shuyuan Xu、Zelong Li、Gerard de Melo 和 Yongfeng Zhang。2021年。HOOPS：人在回路中的图推理，用于对话式推荐。载于 SIGIR。2415–2421。[10] Chongming Gao、Wenqiang Lei、Xiangnan He、Maarten de Rijke 和 Tat-Seng Chua。2021年。对话式推荐系统的进展与挑战：综述。《AI Open》2（2021年），100–126。[11] R Devon Hjelm、Alex Fedorov、Samuel Lavoie-Marchildon、Karan Grewal、Phil Bachman、Adam Trischler 和 Yoshua Bengio。2019年。通过互信息估计与最大化学习深层表示。载于 ICLR。[12] Ari Holtzman、Jan Buys、Li Du、Maxwell Forbes 和 Yejin Choi。2020年。神经文本退化的奇特案例。载于 ICLR。[13] Binbin Hu、Chuan Shi、Wayne Xin Zhao 和 Philip S. Yu。2018年。利用基于元路径的上下文，通过神经协同注意力模型进行 Top-N 推荐。载于 SIGKDD。1531–1540。[14] Chenhao Hu、Shuhua Huang、Yansen Zhang 和 Yubao Liu。2022年。学习推断用户在对话式推荐中的隐式偏好。载于 SIGIR。256–266。[15] Haozhe Ji、Pei Ke、Shaohan Huang、Furu Wei、Xiaoyan Zhu 和 Minlie Huang。2020年。在常识知识图谱上通过多跳推理进行语言生成。载于 EMNLP。725–736。[16] Dongyeop Kang、Anusha Balakrishnan、Pararth Shah、Paul Crook、Y-Lan Boureau 和 Jason Weston。2019年。推荐即通信博弈：面向目标导向对话的自监督机器人对弈。载于 EMNLP-IJCNLP。1951–1961。[17] J. F. Kelley。1984年。面向用户友好的自然语言办公信息应用的迭代式设计方法。《ACM 信息系统汇刊》2，1（1984年），26–41。[18] Wenqiang Lei、Xiangnan He、Yisong Miao、Qingyun Wu、Richang Hong、Min-Yen Kan 和 Tat-Seng Chua。2020年。估计–行动–反思：迈向对话系统与推荐系统之间的深度交互。载于 WSDM。304–312。[19] Wenqiang Lei、Gangyi Zhang、Xiangnan He、Yisong Miao、Xiang Wang、Liang Chen 和 Tat-Seng Chua。2020年。图上的交互式路径推理，用于对话式推荐。载于 SIGKDD。2073–2083。[20] Raymond Li、Samira Ebrahimi Kahou、Hannes Schulz、Vincent Michalski、Laurent Charlin 和 Chris Pal。2018年。迈向深度对话式推荐。NeurIPS 31。[21] Lizi Liao、Yunshan Ma、Xiangnan He、Richang Hong 和 Tat-Seng Chua。2018年。知识感知多模态对话系统。载于 ACM MM。801–809。[22] Allen Lin、Ziwei Zhu、Jianling Wang 和 James Caverlee。2023年。增强对话式推荐系统中的用户个性化。WWW（2023年）。[23] Zhouhan Lin、Minwei Feng、Cícero Nogueira dos Santos、Mo Yu、Bing Xiang、Bowen Zhou 和 Yoshua Bengio。2017年。结构化自注意力句子嵌入。载于 ICLR。[24] Z Liu、H Wang、ZYu Niu、Hua Wu、W Che 和 T Liu。2020年。迈向基于多类型对话的对话式推荐。载于 ACL。1036–1049。[25] Wenchang Ma、Ryuichi Takanobu、Minghao Tu 和 Minlie Huang。2020年。弥合对话推理与交互式推荐之间的鸿沟。arXiv 预印本 arXiv:2010.10333（2020年）。[26] Seungwhan Moon、Pararth Shah、Anuj Kumar 和 Rajen Subba。2019年。OpenDialKG：通过知识图谱上的基于注意力的游走实现可解释对话推理。载于 ACL。845–854。

[27] Jekaterina Novikova、Ondřej Dušek、Amanda Cercas Curry 和 Verena Rieser。2017年。为什么我们需要新的自然语言生成评估指标。在《2017年自然语言处理实证方法会议论文集》中。2241–2252。[28] Lin Qiu、Yunxuan Xiao、Yanru Qu、Hao Zhou、Lei Li、Weinan Zhang 和 Yong Yu。2019年。用于多跳推理的动态融合图网络。在 ACL。6140–6150。[29] Alec Radford、Jeffrey Wu、Rewon Child、Dvid Luan、Dario Amodei 和 Ilya Sutskever。2019年。语言模型是无监督多任务学习器。在 OpenAI 博客。[30] Xuhui Ren、Hongzhi Yin、Tong Chen、Hao Wang、Zi Huang 和 Kai Zheng。2021年。在对话式推荐中学习提出恰当的问题。在 SIGIR（SIGIR）。808–817。[31] Xuhui Ren、Hongzhi Yin、Tong Chen、Hao Wang、Nguyen Quoc Viet Hung、Zi Huang 和 Xiangliang Zhang。2020年。CRSAL：采用对抗学习的对话式推荐系统。《ACM 信息系统汇刊》38，4（2020）。[32] Rajdeep Sarkar、Koustava Goswami、Mihael Arcan 和 John P. McCrae。2020年。今晚给我推荐一部电影：利用知识图谱进行对话式推荐。在国际计算语言学大会。4179–4189。[33] Andrew I. Schein、Alexandrin Popescul、Lyle H. Ungar 和 David M. Pennock。2002年。冷启动推荐的方法与评估指标。在 SIGIR。253–260。[34] Michael Schlichtkrull、Thomas N. Kipf、Peter Bloem、Rianne van den Berg、Ivan Titov 和 Max Welling。2018年。使用图卷积网络对关系数据建模。在《语义网》中。593–607。[35] Michael Schlichtkrull、Thomas N. Kipf、Peter Bloem、Rianne van den Berg、Ivan Titov 和 Max Welling。2018年。使用图卷积网络对关系数据建模。在欧洲语义网大会，Aldo Gangemi、Roberto Navigli、Maria-Esther Vidal、Pascal Hitzler、Raphaël Troncy、Laura Hollink、Anna Tordai 和 Mehwish Alam（编）。593–607。[36] Vered Shwartz、Peter West、Ronan Le Bras、Chandra Bhagavatula 和 Yejin Choi。2020年。通过自我对话进行无监督常识问答。在 EMNLP。4615–4629。[37] Fan-Yun Sun、Jordon Hoffman、Vikas Verma 和 Jian Tang。2020年。InfoGraph：通过互信息最大化进行无监督和半监督图级表示学习。在 ICLR。[38] Haitian Sun、Tania Bedrax-Weiss 和 William Cohen。2019年。PullNet：在知识库和文本上通过迭代检索实现开放域问答。在 EMNLP-IJCNLP。2380–2390。[39] Yueming Sun 和 Yi Zhang。2018年。对话推荐系统。在 SIGIR。235–244。[40] Quan Tu、Shen Gao、Yanran Li、Jianwei Cui、Bin Wang 和 Rui Yan。2022年。通过层次化信息建模实现对话式推荐。在 SIGIR。2201–2205。[41] Xiang Wang、Xiangnan He、Yixin Cao、Meng Liu 和 Tat-Seng Chua。2019年。KGAT：用于推荐的知识图谱注意力网络。在 SIGKDD。950–€“958。[42] Xiang Wang、Dingxian Wang、Canran Xu、Xiangnan He、Yixin Cao 和 Tat-Seng Chua。2019年。面向推荐的知识图谱可解释推理。人工智能促进协会年会 33，01（2019），5329–5336。[43] Xiaolei Wang、Kun Zhou、Ji-Rong Wen 和 Wayne Xin Zhao。2022年。通过知识增强提示学习迈向统一的对话式推荐系统。在 SIGKDD。1929–1937。[44] Tsung-Hsien Wen、Yishu Miao、Phil Blunsom 和 Steve J. Young。2017年。潜在意图对话模型。在国际机器学习大会。3732–3741。[45] Wenhan Xiong、Thien Hoang 和 William Yang Wang。2017年。DeepPath：一种用于知识图谱推理的强化学习方法。在 EMNLP。564–573。[46] Wenhan Xiong、Mo Yu、Shiyu Chang、Xiaoxiao Guo 和 William Yang Wang。2019年。利用知识感知阅读器改进不完整知识库上的问答。在 ACL。4258–4264。[47] Hu Xu、Seungwhan Moon、Honglei Liu、Bing Liu、Pararth Shah 和 S Yu Philip。2020年。对话式推荐中的用户记忆推理。在国际计算语言学大会。5288–5308。[48] Yi-Ting Yeh 和 Yun-Nung Chen。2019年。QAInfomax：通过互信息最大化学习鲁棒问答系统。在 EMNLP-IJCNLP。3370–3375。[49] Tong Yu、Yilin Shen 和 Hongxia Jin。2019年。一种融合视觉对话的交互式推荐系统。在 SIGKDD。157–€“165。[50] Saizheng Zhang、Emily Dinan、Jack Urbanek、Arthur Szlam、Douwe Kiela 和 Jason Weston。2018年。个性化对话代理：我有一只狗，你也养宠物吗？在 ACL。2204–2213。[51] Xiaoyu Zhang、Xin Xin、Dongdong Li、Wenxuan Liu、Pengjie Ren、Zhumin Chen、Jun Ma 和 Zhaochun Ren。2023年。面向对话式推荐的不完整知识图谱变分推理。在 WSDM。231–239。[52] Yongfeng Zhang、Xu Chen、Qingyao Ai、Liu Yang 和 W. Bruce Croft。2018年。迈向对话式搜索与推荐：系统提问，用户回答。在 CIKM。177–€“186。[53] Zhao Zhang、Fuzhen Zhuang、Hengshu Zhu、Zhiping Shi、Hui Xiong 和 Qing He。2020年。采用层次注意力的关系图神经网络，用于知识图谱补全。人工智能促进协会年会 34，05（2020），9612–9619。[54] Jinfeng Zhou、Bo Wang、Zhitong Yang、Dongming Zhao、Kun Huang、Ruifang He 和 Yuexian Hou。2022年。CR-GIS：通过目标感知兴趣序列建模改进对话式推荐。在国际计算语言学大会。400–411。

[55] Kun Zhou、Wayne Xin Zhao、Shuqing Bian、Yuanhang Zhou、Ji-Rong Wen 和 Jingsong Yu。2020年。通过基于知识图谱的语义融合改进对话式推荐系统。载于 *SIGKDD*。1006–1014。 [56] Yu Zhu、Yu Gong、Qingwen Liu、Yingcai Ma、Wenwu Ou、Junxiong Zhu、Beidou Wang、Ziyu Guan 和 Deng Cai。2019年。通过元路径和自适应注意力 GRU 实现基于查询的交互式推荐。载于 *CIKM*。2585–2593。