arXiv:2303.00311v1 [cs.CL] 1 Mar 2023

利用层次化知识建模对话式推荐系统中的多个用户兴趣

Yuka Okuda, Katsuhito Sudoh、Seitaro Shinagawa 和 Satos hi Nakamura

摘要 对话推荐系统（CRS）是一种通过自然语言对话进行物品推荐的实际应用。此类系统会估计用户兴趣，以提供合适的个性化推荐。用户有时会在不同类别或类型中拥有多种兴趣，但现有研究假设用户只有一种能够由密切相关物品覆盖的独特兴趣。在本研究中，我们提出在对话推荐系统中建模此类多个用户兴趣。我们使用 ReDial 数据集通过实验研究了其影响，结果发现，与基线方法 CR-Walker 相比，所提出的方法能够推荐种类更丰富的物品。

1 引言

推荐系统是许多商业应用中一个颇具吸引力的研究与开发领域。典型的推荐系统会利用协同过滤，根据从其他用户的选择中积累的大量数据向用户推荐物品 [1, 2]。这种方法的一个主要缺点是所谓的冷启动问题 [3]；当目标用户没有任何历史记录，无法据此识别其兴趣与偏好以进行推荐时，就会出现这一问题。通过与用户互动并不断更新其兴趣与偏好，可以缓解这一问题。自然语言对话是用户与推荐系统互动的一种很有前景的方式，尤其适用于经验不足的新用户。对话推荐系统（CRS） [4, 5]是此类推荐系统的一种变体。

对话推荐系统通过对话，根据用户的用户画像向用户推荐物品。用户画像是对用户兴趣的表示，用于推荐 [6]。现有的对话推荐系统研究 [5, 6] 使用依赖于用户的嵌入向量来表示用户画像，并据此选择合适的物品进行推荐。

Yuka Okuda，日本奈良县生驹市奈良先端科学技术大学院大学，电子邮箱：okuda.yuka.ou0@is. naist.jp

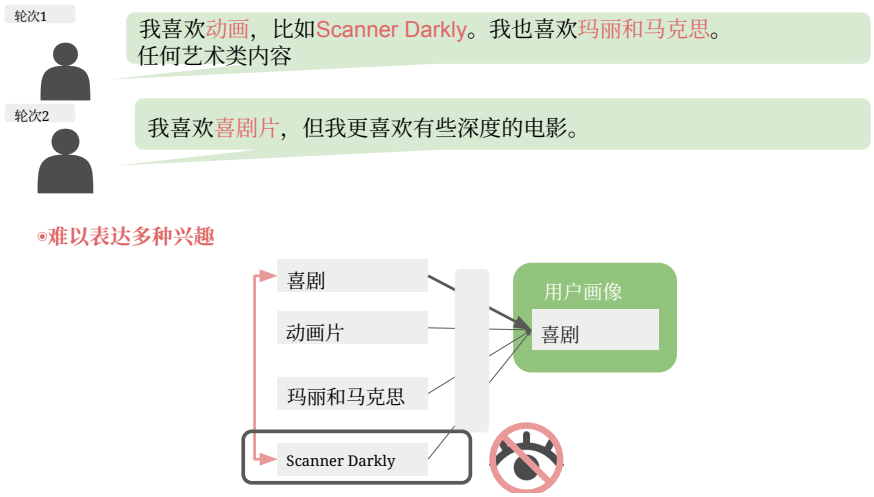

图 1 现有系统难以捕捉用户多种兴趣的案例示意图：顶部展示了两个示例话语，用户话语中的红色文字表示实体，从用户话语中提取的实体以灰色方框表示并纵向排列，绿色边框表示用户画像。

然而，由于画像向量对应嵌入空间中的一个点，这种表示方式会导致推荐物品的多样性有限。在冷启动场景中，用户会在对话过程中逐步表达自己的兴趣，因此其兴趣未必足够具体，无法用这种方式表示。此外，对于兴趣广泛、涉及不同类别或类型的用户，这种表示方式也无法捕捉其多重兴趣。

图 1 展示了电影领域中的一个示例。用户在两段话语中提到了四个实体（两种类型和两个影片名称），随后对话推荐系统根据这些话语估计用户画像。这些类型和影片名称是估计用户画像的重要线索，但将嵌入的加权和计算为单个画像嵌入向量的表示方式，会混合这些不同的兴趣。因此，对话推荐系统无法捕捉用户涵盖不同类型的兴趣，例如动画、喜剧和科幻（由 Scanner Darkly 推断出的类型），并且只推荐侧重于喜剧这一种类型的物品。如果用户要求系统推荐更多物品以扩大覆盖率，系统应该推荐与喜剧相关的类似物品。

本文针对这一问题，提出了一种方法，利用物品和类型的层次化知识，以不同粒度对包含多种兴趣的用户画像进行建模。借助层次化知识，我们可以在不同分支中以适当的粒度保留多种兴趣，例如喜剧这一类型和 Scanner Darkly 这一具体物品。在使用 Re-dial 数据集进行的实验中，所提方法相比使用 CR-Walker 的基线方法推荐了更多样的物品。

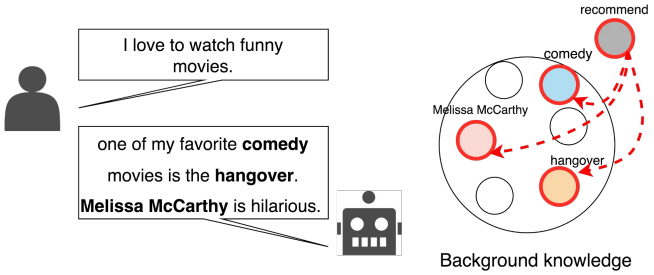

图 2 利用背景知识的对话推荐系统。

2 相关工作

基于自然语言的推荐系统主要有两种方法。一种称为交互式信息检索（IIR），通过自然语言向用户提问。Zhang 等人 [7] 提出了一种信息检索系统，通过提出明确的问题来填充描述用户兴趣的槽位。另一种是对话推荐系统（CRS），它模仿人类进行推荐时的自然语言对话。这种方法具有自然流畅的优势，并采用复杂的对话策略来探索和逐步缩小用户的兴趣范围。本研究基于后一种方法，旨在利用这些优势，在推荐任务中获取多种用户兴趣。

近年来，随着自然语言对话系统和聊天机器人领域的发展，对话推荐系统吸引了众多研究。对话推荐系统中的一个重要问题是融入背景知识，从而做出准确的推荐并生成恰当的系统话语。背景知识是指系统在话语中使用的知识。Zhou 等人 [5] 和 Ma 等人 [6] 着重研究了对话策略与背景知识之间的关系，以实现这些目标。在这些已有研究中，背景知识是根据用户画像、话语上下文、知识关系等进行估计的。CR-Walker [6]使用推理树来获取准确的背景知识。然而，这些研究并未对用户画像建模以捕捉多个用户兴趣。

关于多个用户兴趣的问题，Qi 等人 [8] 提出了一种基于网页浏览点击率、考虑多个用户兴趣的推荐系统。然而，由于他们的系统依赖大规模点击率数据，因此这种方法无法应用于对话推荐系统。

在本文中，我们聚焦于对话推荐系统中的多个用户兴趣问题，并提出一种能够捕捉多个兴趣的用户画像建模方法。

图 3 对话推荐系统概览。

3 CR-Walker：带有用户画像的传统对话推荐系统模型

在介绍所提方法之前，本节先介绍CR-Walker[6]。CR-Walker是一种使用用户画像的传统对话推荐系统方法。它由三个模块组成：话语编码器、用户画像提取器，以及使用推理树的系统话语生成器。其整体架构如图3所示。

3.1 话语编码

假设用户与对话推荐系统在对话中轮流发言，并令x_t和y_t分别表示用户话语和系统话语。话语编码器捕获用户与系统之间对话的上下文表示。用户话语和系统话语首先使用 BERT [9] 转换为嵌入，然后使用长短期记忆网络 [10] 转换为上下文嵌入。直到时间步t用户话语u_t为止的对话上下文嵌入表示为：

$$u_t = \mathrm{LSTM}_{\mathrm{hidden}}\left(u_{t-1}, \mathrm{BERT}\left([y_{t-1}; x_t]\right)\right), \tag{1}$$

其中，下标“hidden”表示向量u_t是时间t时长短期记忆网络的隐藏向量，而不是其输出向量。长短期记忆网络的输入是y_{t-1}和x_t的拼接。

3.2 用户画像提取

用户画像提取器根据用户话语p_t提取用户画像向量$x1,\ldots,x_t$以及知识图谱。它不使用完整的用户话语，而是聚焦于

[1] 由于篇幅有限，我们省略了本文不需要的部分细节。详细表述请参阅相关文献。

所提及实体。这里，我们假设知识图谱表示一组命名实体 $\mathcal{N}$ 之间的关系。

首先，用户画像提取器使用命名实体识别从用户话语中找出命名实体 $E_t = e1$，……，e^{N_t}，其中 N_t 是 $x1$，……，x_t 中提及的实体数量。随后，将这些实体转换为对应的实体嵌入 $M_t = \{h1$，……，$h_{N_t}\}$。每个实体嵌入 h_i 都通过一个 L 层网络计算，其第 l 层的中间嵌入表示为：

$$h_i^{(l)} = \sigma\left(\left(\sum_{r\in\mathcal{R}}\sum_{e'\in\mathcal{N}_{e_i}^r}\frac{1}{|\mathcal{N}_{e_i}^r|}W_r^{(l-1)}h_{e'}^{(l-1)}\right)+W_0^{(l-1)}h_i^{(l-1)}\right), \tag{2}$$

其中，$\mathcal{N}_{rei}$ 是知识图谱中与 e_i 通过关系 r 相连的邻居实体集合，$h^{(l-1)}{}_{e'}$ 是 e' 在 $\mathcal{N}_{rei}$ 第 $l-1$ 层的嵌入向量，$W_r^{(l)} \in \mathbb{R}^{d\times d}$ 和 $W_{(l)}{}_0 \in \mathbb{R}^{d\times d}$ 是可学习矩阵，用于整合来自邻居实体和当前实体的关系特定信息。h_*^0 由嵌入矩阵 $W_{\text{emb}} \in \mathbb{R}^{d\times\mathcal{N}}$ 导出；这意味着无论命名实体是否出现在训练数据中，用户画像提取器模型都涵盖 $\mathcal{N}$ 中的所有命名实体。知识图谱从 DBpedia 中提取，并使用 R-GCN [11]进行表示。

然后，通过对 M_t 进行注意力计算，得到用户画像 $p_t \in \mathbb{R}^d$，如下所示：

$$p_t = \alpha_t * M_t, \tag{3}$$
$$\alpha_t = \text{softmax}\left(w_p \cdot \tanh\left(W_p M_t\right)\right), \tag{4}$$

其中，w^p 是每个实体嵌入的权重，W^p 是自注意力的权重矩阵。

3.3 系统话语生成

根据上述过程提取的用户画像，系统会生成回复，向用户提出更多问题并提供推荐。生成过程包括：(1) 构建推理树，以确定回复中将提及的内容；(2) 使用推理树和语言生成模型生成回复。

3.3.1 推理树

推理树是一种树状结构的图，如图4所示。CR-Walker使用两种类型的节点，分别表示对话行为和知识图谱实体；二者均由根据 u_t 和 p_t 得到的嵌入向量表示。

根节点存储的对话行为嵌入 i_t 表示如下：

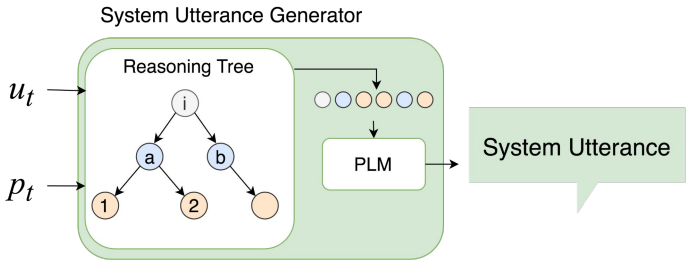

图 4 系统话语生成器。

$$i_t = W_{int}^2 \,\mathrm{ReLU}\left(W_{int}^1 u_t\right), \tag{5}$$

其中，W_{int}^1 和 W_{int}^2 是权重矩阵。对话行为分为三种：推荐、查询和聊天，系统会如后文所述，根据对话行为调整其行为。

与后代节点相关联的向量来自知识图谱实体的嵌入，但也受到其祖先节点的影响。为每个后代节点定义一个上下文嵌入 c_t，如下所示[2]:

$$c_t = \gamma_t u_t + (1-\gamma_t)\, p_t, \tag{6}$$

$$\gamma_t = \begin{cases} \sigma\left(w_1 \cdot [u_t; p_t; i_t]\right), & \text{(if the parent is the root)} \\ \sigma\left(w_2 \cdot \left[u_t; p_t; i_t; h_{e_{\text{parent}}}\right]\right), & \text{(otherwise)} \end{cases} \tag{7}$$

其中，w_1 和 w_2 表示权重向量，$h^{e_{\text{parent}}}$ 是与父节点相关联的实体的嵌入，而 $[a;b]$ 表示向量拼接。

假设我们要向推理树中添加一个与实体 e' 相关联的子节点。我们使用其祖先节点的上下文嵌入定义一个分数 $\hat{s}_{e'}$，如下所示:

$$\hat{s}_{e'} = \left(h_{e'} \cdot \left(c_t + c_t^{\text{parent}}\right)\right), \tag{8}$$

其中 c_t 是我们要追加子节点的节点的上下文向量，而 c_t^{parent} 是其父节点的上下文向量。请注意，c_t^{parent} 是递归计算的，直到根节点为止。根据该分数，所有满足函数 WALK(e) $=\{e' \mid \hat{s}_{e'} > \tau\}$ 的实体都会在推理树中形成新节点[3]。阈值超参数 τ 控制推理树中所包含实体的选择。节点追加步骤重复 N 次，以生成一个（$N+1$）层推理树。CR-Walker生成一个三层推理树，其节点根据对话行为表示不同类型的实体，如表1所示。对话行为*Recommend* 使

[2] 为简洁起见，我们省略了用于指定节点的上标。[3] 如果所有实体的评分都低于 τ，则WALK(e)返回排名第一的实体。

表1 不同对话行为对应的推理树中存储的实体类型。

对话行为（根层）	中间层	叶层
推荐	所提及项目的属性 候选项目	
查询	通用类别	属性
Chat	所提及实体	所有实体

系统向用户推荐物品。*Query* 和*Chat* 分别使系统向用户提问，以及谈论所提及实体的相关内容。

3.3.2 话语生成

系统基于推理树生成话语。推理树首先被转换为序列，然后作为预训练语言模型的输入提示，用于预测遵循该输入提示的系统话语。

4 所提方法

我们提出了一种扩展 CR-Walker 的用户画像提取器的方法，用于捕捉广泛的用户兴趣。所提方法利用实体知识的层级结构，并显式考虑多个抽象物品类别（即类型），以计算用户画像向量。

在这项工作中，我们假设实体知识具有物品层级结构：在电影领域中，该结构由类型和影片名称组成。我们的动机是捕捉跨越不同类型的多种用户兴趣。CR-Walker 诱导的用户画像基于实体嵌入，并通过注意力机制聚焦于数量有限的实体（公式（3）—（4））。相比之下，所提方法旨在通过推理树诱导过程中的显式类型级用户画像，捕捉不同类型中的用户兴趣。

4.1 层次化物品知识

我们假设目标领域中的物品知识可用，并包含有关物品类别的信息。我们利用这些知识构建如图 5 所示的层次结构，其中包含物品节点（例如电影名称）和抽象类别节点（例如电影类型）。为简化起见，我们假设每个物品仅关联一个抽象类别。

我们为层次化知识中的节点分配嵌入向量。每个项目节点的嵌入向量，简单来说就是其项目描述中名词和形容词嵌入的平均值；对于

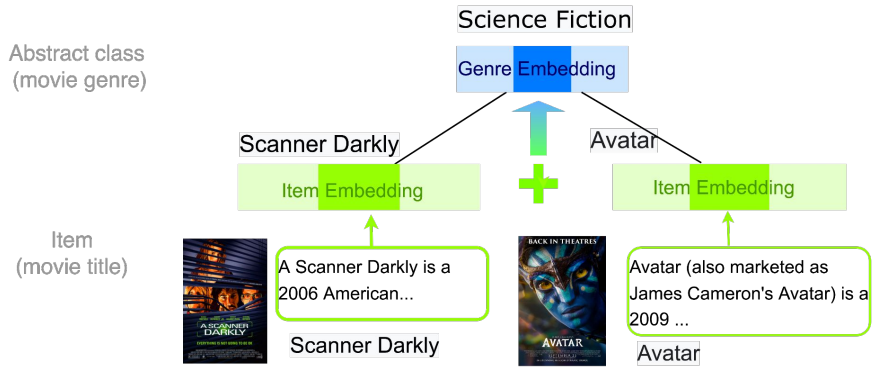

图 5 构建层次化知识。

电影而言，就是摘要。每个抽象类别节点的嵌入向量则是与之关联的物品节点嵌入的平均值。嵌入模型是预训练模型，例如 word2vec。例如，在图 5 中，类型节点 科幻 的嵌入是物品节点*Scanner Darkly* 和 阿凡达嵌入的平均值。

4.2 考虑多种兴趣的用户画像提取

我们将用户话语与层次化知识中每个节点嵌入之间的相似度计算为这两个向量的余弦相似度。用户话语的向量表示方式与项目节点相同。对话中的用户话语会更新节点得分；余弦相似度会累积为每个节点的得分，S_t^H。

利用这些节点得分，我们提取用户画像向量 p_t^H，并将其用于推理树的中间层，以根据用户对抽象类别的兴趣来约束推荐。我们选择得分最高的两个属性实体 e_1^H 和 e_2^H，以考虑用户在不同属性上的多个兴趣。它们对应的实体嵌入h_1^H 和 h_2^H 用于计算用户画像 p_t^H，如下所示：

$$p_t^H = \alpha_t^H * M_t^H, \tag{9}$$

$$\alpha_t^H = \mathrm{softmax}\left(w_p \cdot \tanh\left(W_p M_t^H\right)\right), \tag{10}$$

$$M_t^H = (h_1^H, h_2^H). \tag{11}$$

请注意，我们使用与 CR-Walker 相同的 w_p 和 W_p。用户画像 p_t^H 仅用于属性级推理，而在物品级推理中仍使用原始用户画像 p_t。

5 实验

我们通过以下实验研究所提方法的性能，并将其与 CR-Walker 基线方法进行比较。

5.1 设置

在实验中，我们使用了 ReDial [4],这一公开的电影领域对话推荐数据集。每段推荐对话均由两名众包工作者进行；一人扮演推荐者，另一人扮演寻求者。推荐者的话语均标注了其正确的推荐物品（电影名称）。在每段对话中，至少提及四部不同的电影。

作为基线方法，我们使用了 CR-Walker[4] 作者的实现，并进行了以下修改：(1) 用于 M_t 在公式 (3) 中诱导用户画像的实体，被限制为电影类型，以便与所提方法进行一致的比较；(2) 当对话行为为 *Recommend* 时，系统从电影属性（如类型、年份、演员等）的实体中选择中间层的 top-1 实体，并在叶层选择 top-2 电影名称，以此诱导推理树[5]。

所提方法所用的资源准备如下。电影类型和影片名称的层级知识来自 CR-Walker 的实现，而这些知识最初是从 DBpedia 中提取的。每部电影的摘要描述取自相应的 DBpedia 条目和维基百科文章；若 DBpedia 条目中有相关内容，我们便从中提取，否则使用简单的匹配模式“*[*电影名称*]* 是.....”来提取摘要描述。所提方法使用的词嵌入来自预训练的 word2vec 模型 *GoogleNews-vectors-negative30word2vec*[6]以及自然语言工具包[7]。

[4] https://github.com/truthless11/CR-Walker[5] 我们观察到，3.3.1 中描述的基于阈值的实体选择在大多数情况下会产生排名第一的实体，因此这一修改不会严重影响 CR-Walker 的性能。[6] https://code.google.com/archive/p/word2vec[7] https://www.nltk.org/

表2 推荐的召回率@K（R@K）和覆盖率（Cov.）。

模型	R@1	R@10	R@50	覆盖率
CR-Walker	3.33	14.6	30.5	17.4
提出的方法	3.23	14.5	30.2	**21.1**

表3 BLEU、多样性（dist）-1/2/3 以及话语生成结果的 F1。

模型	BLEU	多样性-1	多样性-2	多样性-3	F1
CR-Walker	7.62	5.5	23.0	39.1	15.64
所提方法	7.64	**6.1**	**24.3**	**40.4**	15.63

表 4 基线方法 CR-Walker 和所提方法进行推荐与话语生成的示例。中间层实体（属性）和叶层实体（物品）均源自推理树。

轮次	模型	话语	对话行为	中部层	叶层
1	User	我喜欢观看**喜剧电影**			
	CR-Walker	我最喜欢的喜剧电影是《宿醉》。梅丽莎·麦卡西非常搞笑。我也真的像《伴娘》这样的电影	推荐喜剧		(1)《宿醉》(2)《伴娘》
	提议	我的其中一个最喜欢的喜剧电影是《宿醉》。梅丽莎麦卡西很搞笑。我也非常喜欢《伴娘》	推荐喜剧		(1)《宿醉》(2)《伴娘》
2	User	是的，我喜欢亚当·桑德勒			
	CR-Walker	你看过《人生遥控器》或者《水孩子》boy?	推荐美国电影		(1)《人生遥控器》(2)《The》饮水员
	提议	你看过《人生遥控器》或《呆呆向前冲》吗？boy?	推荐喜剧		(1)《人生遥控器》(2)《《水孩子》
3	User	昨晚刚看了《变相怪杰》！新出了一部《变相怪杰2》。我喜欢一些**恐怖电影**			
	CR-Walker	你看过《阿呆闯学堂》或者《神探飞机头》吗：宠物侦探?	推荐 **喜剧**		(1)《阿呆闯学堂》(2) Ace 文图拉：宠物侦探
	推荐	你看过《塔克与戴尔对决》邪恶对决吗？或者《小妖精》？	推荐**恐怖片**		(1) 塔克 and Dale vs. Evil (2)《小妖精》

5.2 结果

首先，我们使用 Recall@K 和覆盖率评估推荐性能。Recall@K 表示排名前 K 的检索结果的召回率，是信息检索中广泛使用的指标。覆盖率通过特定测试集中被推荐的不同物品数量与物品集合大小的比值，衡量物品推荐的多样性。表2展示了结果。所提方法的 Recall@K 未超过 CR-Walker，但覆盖率更高。这表明，与 CR-Walker 相比，所提方法的推荐覆盖了更广泛的物品范围，但也会降低推荐物品的准确性。

随后，我们使用 BLEU[12], 、distinct-N [13], 和 F1 对话语生成的性能进行了测量。表3展示了结果。所提方法的 distinct 分数略高于 CR-Walker，而 BLEU 和 F1 几乎相同。这表明，所提方法由于推荐策略的变化，能够生成更多样的话语，且与此前结果中的发现一致地表明了这一点。

这是由于推荐策略的变化所致，也与此前结果中的发现一致。

5.3 分析

5.3.1 推荐与话语生成

我们分析了 CR-Walker 和所提方法的推荐与话语生成结果。表 4 展示了一个示例。推理树中的中间层（属性）和叶层（物品）也用于约束话语生成。用户在第一轮话语中表示了对有趣的（喜剧）电影的兴趣，两个系统的表现相同。下一轮中，它们的表现也相似。第三轮中，用户提到了对恐怖（恐怖片）电影的兴趣。CR-Walker 仍局限于喜剧这一类型，而所提方法则成功捕捉到用户对恐怖片的兴趣，并推荐兼具喜剧和恐怖元素的电影。

5.3.2 不同类型间用户兴趣的转移

我们研究了实验中不同类型间用户兴趣的转移。表 6 和表 7 分别展示了 CR-Walker 和所提方法在一段对话中中间层（属性）之间的转移概率。表中的每个单元格均根据相应的转移概率着色。两者的差异清楚地表明，所提方法产生的 top-1 属性转移更多。这表明，所提方法能够适应用户画像因多个用户兴趣而可能发生的变化。

6 结论

在这项工作中，我们提出了一种为对话推荐系统建模多个用户兴趣的方法。所提方法利用抽象类别和物品的层次化知识，并将多个抽象类别明确纳入用于推荐和话语生成的用户画像中。它根据词嵌入衡量的估计用户兴趣与层次化知识中各节点之间的相似度，利用用户画像生成推理树。使用 ReDial 数据集进行的实验结果表明，与 CR-Walker 相比，所提方法推荐的物品种类更多，生成的话语也更加多样。我们的详细分析还表明，所提方法能够捕捉不同类别中的多个用户兴趣。

未来的工作包括使用所提系统开展用户研究，而非基于给定的 ReDial 对话上下文进行调查；探索更复杂的对话推荐策略以缩小用户兴趣范围；以及对完整的对话推荐系统进行适当评估。

	Comedy	Horror	Drama	Documentary	Action	Adventure	Animation	Romance	Children	Sci-Fi	Mystery	Thriller	Musical	Crime	Fantasy	War	Western	Film-Noir
Comedy	2.03E-01	0.00E+00	3.35E-03	0.00E+00	7.82E-03	7.45E-04	2.98E-03	0.00E+00	7.45E-04	0.00E+00	0.00E+00	0.00E+00	0.00E+00	7.45E-04	1.49E-03	0.00E+00	7.45E-04	0.00E+00
Horror	2.98E-03	1.60E-02	4.10E-03	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	4.47E-03	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
Drama	1.12E-02	3.73E-03	4.66E-02	7.45E-04	4.84E-03	0.00E+00	2.98E-03	3.73E-04	1.12E-03	1.12E-03	0.00E+00	5.22E-04	0.00E+00	9.94E-04	1.49E-03	0.00E+00	0.00E+00	0.00E+00
Documentary	0.00E+00	0.00E+00	0.00E+00	4.22E-03	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	2.48E-04	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
Action	3.73E-04	0.00E+00	1.12E-03	0.00E+00	1.42E-01	0.00E+00	3.73E-04	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
Adventure	7.45E-04	0.00E+00	7.45E-04	0.00E+00	0.00E+00	4.72E-03	7.45E-04	0.00E+00	7.45E-04	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
Animation	7.45E-04	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	1.51E-02	0.00E+00	0.00E+00	0.00E+00	0.00E+00	7.45E-04	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
Romance	0.00E+00	0.00E+00	1.49E-03	0.00E+00	1.49E-03	0.00E+00	0.00E+00	2.24E-03	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
Children	7.45E-04	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	1.86E-03	0.00E+00	6.33E-03	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
Sci-Fi	0.00E+00	0.00E+00	0.00E+00	0.00E+00	7.45E-04	0.00E+00	0.00E+00	0.00E+00	0.00E+00	4.47E-03	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
Mystery	0.00E+00	0.00E+00	0.00E+00	0.00E+00	7.45E-04	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	7.45E-04	0.00E+00	0.00E+00	0.00E+00	0.00E+00
Thriller	0.00E+00	3.75E-03	2.98E-03	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	8.92E-03	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
Musical	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	7.45E-04	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
Crime	0.00E+00	0.00E+00	2.61E-03	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	6.33E-03	0.00E+00	0.00E+00	0.00E+00	0.00E+00
Fantasy	7.45E-04	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	4.47E-03	0.00E+00	0.00E+00	0.00E+00
War	0.00E+00	0.00E+00	7.45E-04	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
Western	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	7.45E-04	0.00E+00
Film-Noir	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00

Fig. 6 Transition probability of CR-Walker.

	Comedy	Horror	Drama	Documentary	Action	Adventure	Animation	Romance	Children	Sci-Fi	Mystery	Thriller	Musical	Crime	Fantasy	War	Western	Film-Noir
Comedy	4.21E-04	4.34E-05	6.52E-06	0.00E+00	1.96E-05	2.39E-05	1.74E-05	0.00E+00	2.10E-05	2.61E-05	2.17E-06	1.45E-06	1.23E-05	2.17E-06	2.10E-05	1.45E-06	1.45E-06	0.00E+00
Horror	6.32E-05	4.44E-04	5.65E-06	2.26E-06	1.69E-05	1.02E-05	1.02E-05	1.13E-06	6.77E-06	1.58E-05	4.52E-06	1.13E-06	3.39E-06	2.26E-06	4.52E-06	3.39E-06	0.00E+00	0.00E+00
Drama	7.67E-05	5.48E-05	1.86E-04	1.10E-05	6.57E-05	2.19E-05	1.10E-05	1.10E-05	0.00E+00	3.29E-05	1.10E-05	1.10E-05	0.00E+00	0.00E+00	2.19E-05	4.38E-05	0.00E+00	0.00E+00
Documentary	5.52E-05	0.00E+00	0.00E+00	5.24E-04	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	2.76E-05	0.00E+00	0.00E+00	0.00E+00
Action	6.97E-05	2.42E-05	9.09E-06	3.03E-06	3.12E-04	3.94E-05	3.03E-06	0.00E+00	6.06E-06	4.85E-05	3.03E-06	3.03E-06	6.06E-06	3.03E-06	1.21E-05	3.03E-06	3.03E-06	0.00E+00
Adventure	1.04E-04	6.01E-05	3.34E-06	0.00E+00	5.35E-05	2.61E-04	2.34E-05	3.34E-06	1.34E-05	4.34E-05	0.00E+00	0.00E+00	1.34E-05	6.68E-06	2.34E-05	0.00E+00	0.00E+00	0.00E+00
Animation	5.42E-05	3.79E-05	0.00E+00	0.00E+00	2.98E-05	1.63E-05	4.06E-04	0.00E+00	4.34E-05	8.13E-06	2.71E-06	5.42E-06	2.71E-06	0.00E+00	1.90E-05	0.00E+00	0.00E+00	0.00E+00
Romance	5.73E-05	5.73E-05	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	5.73E-05	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
Children	8.64E-05	3.24E-05	0.00E+00	3.60E-06	2.16E-05	1.44E-05	8.64E-05	0.00E+00	3.10E-04	3.60E-06	7.20E-06	3.60E-06	7.20E-06	0.00E+00	3.60E-05	0.00E+00	0.00E+00	0.00E+00
Sci-Fi	6.74E-05	3.77E-05	7.93E-06	0.00E+00	2.38E-05	3.77E-05	1.39E-05	1.98E-06	1.98E-05	3.73E-04	1.98E-06	0.00E+00	3.96E-06	3.96E-06	3.17E-05	0.00E+00	0.00E+00	0.00E+00
Mystery	1.09E-04	1.09E-04	1.82E-05	0.00E+00	5.45E-05	0.00E+00	0.00E+00	0.00E+00	1.82E-05	0.00E+00	2.73E-04	3.63E-05	0.00E+00	0.00E+00	3.63E-05	0.00E+00	0.00E+00	0.00E+00
Thriller	4.66E-05	1.40E-04	0.00E+00	0.00E+00	0.00E+00	4.66E-05	0.00E+00	0.00E+00	0.00E+00	4.66E-05	1.86E-04	9.31E-05	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
Musical	9.64E-05	0.00E+00	1.75E-05	0.00E+00	8.77E-06	8.77E-06	4.38E-05	8.77E-06	7.01E-05	0.00E+00	0.00E+00	0.00E+00	3.59E-04	0.00E+00	8.77E-06	0.00E+00	8.77E-06	0.00E+00
Crime	5.59E-05	1.86E-05	3.73E-05	0.00E+00	3.73E-05	3.73E-05	0.00E+00	0.00E+00	0.00E+00	1.86E-05	0.00E+00	0.00E+00	0.00E+00	3.54E-04	1.86E-05	0.00E+00	0.00E+00	0.00E+00
Fantasy	5.26E-05	4.88E-05	0.00E+00	3.75E-06	2.63E-05	3.38E-05	3.38E-05	3.75E-06	2.25E-05	2.63E-05	3.75E-06	3.75E-06	3.75E-06	7.51E-06	3.19E-04	0.00E+00	0.00E+00	0.00E+00
War	5.32E-05	0.00E+00	3.19E-04	0.00E+00	1.06E-04	5.32E-05	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	5.32E-05	0.00E+00	0.00E+00	1.06E-04	0.00E+00	0.00E+00
Western	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	6.77E-05	6.77E-05	0.00E+00	6.77E-05	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	2.03E-04	0.00E+00
Film-Noir	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00

Fig. 7 Transition probability of the proposed method.

参考文献

1. Joeran Beel、Bela Gipp、Stefan Langer 和 Corinna Breitinger。科研论文推荐系统：文献综述。*International Journal on Digital Libraries*，17(4):305–338，2016。2. Xiangnan He、Lizi Liao、Hanwang Zhang、Liqiang Nie、Xia Hu 和 Tat-Seng Chua。神经协同过滤。载于第 *26* 届 *World Wide Web* 国际会议论文集，2017。3. Jyotirmoy Gope 和 Sanjay Kumar Jain。解决推荐系统冷启动问题的综述。载于*2017* 年国际计算、通信与自动化会议，2017。4. Raymond Li、Samira Kahou、Hannes Schulz、Vincent Michalski、Laurent Charlin 和 Chris Pal。迈向深度对话推荐。载于第 *32* 届 *Neural Information Processing Systems* 国际会议论文集，2018。5. Kun Zhou、Wayne Xin Zhao、Shuqing Bian、Yuanhang Zhou、Ji-Rong Wen 和 Jingsong Yu。通过基于知识图谱的语义融合改进对话式推荐系统。载于第 *26* 届 *ACM Knowledge Discovery & Data Mining* 国际会议论文集，KDD ’20，第 1006–1014 页，美国纽约州纽约，2020。计算机协会。6. Wenchang Ma、Ryuichi Takanobu 和 Minlie Huang。CR-Walker：用于对话式推荐的树结构图推理与对话行为。载于*2021* 年 *Empirical Methods in Natural Language Processing* 会议论文集，第 1839–1851 页。ACL，2021。7. Yongfeng Zhang、Xu Chen、Qingyao Ai、Liu Yang 和 W. Bruce Croft。迈向对话式搜索与推荐：系统提问，用户回应。载于第 *27* 届 *ACM* 信息与知识管理国际会议论文集，CIKM ’18，第 177–186 页，美国纽约州纽约，2018。计算机协会。8. Tao Qi、Fangzhao Wu、Chuhan Wu、Peiru Yang、Yang Yu、Xing Xie 和 Yongfeng Huang。HieRec：用于个性化新闻推荐的层次化用户兴趣建模。载于第 *59* 届 *Association for Computational Linguistics* 年会暨第 *11* 届自然语言处理国际联合会议论文集（第 *1* 卷：长篇论文），第 5446–5456 页，线上，2021 年 8 月。Association for Computational Linguistics。9. Jacob Devlin、Ming-Wei Chang、Kenton Lee 和 Kristina Toutanova。BERT：用于语言理解的深度双向Transformer预训练。载于 *2019* 年北美计算语言学协会分会会议论文集：人类语言技术，第 *1* 卷（长篇与短篇论文），第 4171–4186 页，美国明尼苏达州明尼阿波利斯，2019 年 6 月。Association for Computational Linguistics。10. Has˙im Sak、Andrew Senior 和 Franc¸oise Beaufays。用于大词汇量语音识别的长短期记忆循环神经网络架构。*arXiv* 预印本 *arXiv:1402.1128*，2014。11. Michael Schlichtkrull、Thomas N Kipf、Peter Bloem、Rianne van den Berg、Ivan Titov 和 Max Welling。使用图卷积网络建模关系数据。载于*European semantic web conference*，第 593–607 页。Springer，2018。12. Kishore Papineni、Salim Roukos、Todd Ward 和 Wei-Jing Zhu。BLEU：一种机器翻译自动评估方法。载于第 *40* 届 *Association for Computational Linguistics* 年会论文集，第 311–318 页，美国宾夕法尼亚州费城，2002 年 7 月。Association for Computational Linguistics。13. Jiwei Li、Michel Galley、Chris Brockett、Jianfeng Gao 和 Bill Dolan。用于神经对话模型的促进多样性的目标函数。载于*2016* 年北美计算语言学协会分会会议论文集：人类语言技术，第 110–119 页，美国加利福尼亚州圣迭戈，2016 年 6 月。Association for Computational Linguistics。