

## 基于时序推理的分层会话感知推荐模型

罗鹏宇<sup>1</sup> 吴乐<sup>1</sup> 吕扬<sup>2</sup> 袁堃平<sup>3</sup> 洪日昌<sup>1</sup>

1 合肥工业大学计算机与信息学院 合肥 230009

2 中国科学技术大学信息科学技术学院 合肥 230027

3 北京邮电大学信息与通信工程学院 北京 100876

(luopengyu@mail.hfut.edu.cn)

**摘要** 基于会话的推荐系统,旨在根据匿名会话预测用户下一时刻的行为,这在很多互联网服务中颇为常见。该问题的主要挑战在于,如何模拟目标会话中用户行为的时序关系,并利用有限长度的会话刻画用户的兴趣。现有的方法根据目标会话中邻近物品的时序关系来建模用户的行为模式,并对目标会话中的物品信息进行选择性地保留和利用,进而聚合为会话的整体特征,并将其作为目标会话对应的用户兴趣。为了更好地建模用户行为模式和用户兴趣,文中提出了一种基于时序推理的分层会话感知推荐模型。一方面,不同于以往工作对目标会话中“邻近物品即相关”的假设,文中对目标会话中交互物品之间的依赖关系进行推理,并在会话中学习更灵活的时序关系,以建模用户的行为模式;另一方面,从目标会话中的物品和物品特征两个层次进行物品信息的聚合,实现更细粒度的用户兴趣推断。在两个公共数据集上的实验中,所提模型均优于其他基准模型,验证了其有效性。

**关键词:** 基于会话的推荐系统;匿名会话;时序推理;用户兴趣;神经网络

**中图分类号** TP311

## Temporal Reasoning Based Hierarchical Session Perception Recommendation Model

LUO Peng-yu<sup>1</sup>, WU Le<sup>1</sup>, LYU Yang<sup>2</sup>, YUAN Kun-ping<sup>3</sup> and HONG Ri-chang<sup>1</sup>

1 School of Computer Science and Information Engineering, Hefei University of Technology, Hefei 230009, China

2 School of Information Science and Technology, University of Science and Technology of China, Hefei 230027, China

3 School of Information and Communication Engineering, Beijing University of Posts and Telecommunications, Beijing 100876, China

**Abstract** Session-based recommendation, which aims at predicting the user's next action based on anonymous sessions, becomes a critical task in many online services. The main challenges of this problem are how to model the temporal relationship of user's behaviors within the target session and capture user's interest by the limited interactions. Existing methods model the user's behavior patterns based on the temporal relationship of adjacent items within the target session, and aggregate the item information in the target session into overall session representation as the corresponding user's interest. In order to improve these two processes, a novel Temporal Reasoning Based Hierarchical Session Perception Model (TRHSP) for session-based recommendation is proposed. On the one hand, unlike the previous works which assume adjacent items are related, TRHSP infers the dependency relationship between adjacent items in the target session and learns to handle the user-item interaction sequence with a flexible order, which helps to model user's behavior. On the other hand, TRHSP aggregates the item information of the target session from both the item level and the item feature level, so as to capture user's interest in a more fine-grained manner. In the experiments on two public datasets, the proposed TRHSP achieves the best performance, thus proving the effectiveness of the model.

**Keywords** Session-based recommendation, Anonymous session, Temporal reasoning, User's interest, Neural network

## 1 引言

随着大数据时代的来临,互联网中的各类信息呈指数式增长,导致了严重的信息过载问题,而推荐系统是解决信息过

载问题的重要方法之一。在很多应用场景下,用户往往是第一次/匿名浏览,此时用户的属性和以往的交互记录对于推荐系统而言都是不可知的。为了解决这个问题,基于会话的推荐系统(Session-based Recommender Systems, SRS)被提

到稿日期:2020-07-14 返修日期:2020-08-23

本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金(61972125),中央高校基本科研业务经费(JZ2020HGPA0114)

This work was supported by the National Natural Science Foundation of China(61972125) and Fundamental Research Funds for the Central Universities (JZ2020HGPA0114).

通信作者:吴乐(lewu@hfut.edu.cn)

出<sup>[1]</sup>,并成为了近年来的热门研究方向。SRS问题的定义为,仅仅依赖目标会话中的有限交互行为(如点击行为)来预测下一个可能交互的物品。图1展示了一个典型的SRS应用,其中服务器为每一个会话创建了特定的标识,并由此跟踪用户的点击行为。




图1 基于会话的典型推荐场景

Fig.1 Typical scenario for session-based recommendation

SRS问题的主要挑战在于,如何模拟目标会话中用户行为的时序关系,并在有限长度的会话中刻画用户的兴趣。为了应对这些挑战,现有的方法根据目标会话中邻近物品的时序关系来建模用户的行为模式,并将目标会话中的物品信息聚合为会话的整体特征,作为目标会话对应的用户兴趣。

SRS问题使用的点击序列数据主要有以下两个特性:

(1)在很多现实场景中,由于用户行为的不确定性,会话中包含了一些错误交互物品和一些会对下一步预测产生干扰的不相关交互。例如,在一个购物序列{熏肉,玫瑰,鸡蛋,面包}中,这里的“玫瑰”很有可能是噪声,因为它与序列中的其他商品几乎不相关。下一个最可能被点击的物品应该是牛奶,这仅取决于熏肉、鸡蛋和面包,与玫瑰可能并没有关系,而时序推理恰好可以缓解上述假设存在的问题。

(2)一个用户-物品交互的序列可能并不是点式的依赖关系,而存在着复杂的集合依赖项。例如,在一个购物序列{牛奶,黄油,面粉}中,牛奶和黄油之间没有严格的顺序,但是面粉的顺序会取决于它们的组合。因此,对于一个灵活排序的序列,需要更好地捕获集合形式的而不是点式的顺序依赖关系。

当前性能表现较好的SRS模型<sup>[1-2]</sup>多为基于循环神经网络(Recurrent Neural Networks, RNNs)的深度学习模型。其通过循环神经网络捕获整个用户点击行为序列的顺序,以捕获用户的行为模式。例如, Hidasi等<sup>[1]</sup>通过引入门控循环单元(Gated Recurrent Unit, GRU)<sup>[3]</sup>来建模会话序列中的行为模式,并提出了GRU4Rec模型。但是,当前将循环神经网络应用于基于会话的推荐工作存在着以下两个问题:

(1)循环神经网络假设会话中任何邻近的物品一定存在依赖关系,缺乏对噪声点击的有效甄别。循环神经网络显然假设过强,并可能学习到错误的依赖关系。

(2)循环神经网络忽略了物品的集合依赖关系,导致学习能力有限。

事实上,为了更有效地建模含噪声的交互序列,处理其中弱相关甚至不相关的物品,有不少工作<sup>[2,4-5]</sup>试图利用注意力网络来解决这个问题,从那些真正与下一步交互预测相关的信息中有选择地保留和利用信息,表示为用户兴趣。例如, Li等<sup>[2]</sup>对GRU4Rec模型进行了改进,具体而言,其通过注意力机制对目标会话中的物品进行差异性关注,以推断会话中隐

藏的用户偏好。然而,之前的注意力模型往往并未考虑不同物品特征的特定部分,而是仅仅将物品视为一个整体,忽略了物品内蕴含的丰富的多样性信息,导致无法在目标会话中捕捉到完整的用户兴趣。例如,在电影推荐场景中,某用户在连续观看了《星际穿越》和《极乐空间》后,同样由马特·达蒙主演的《火星救援》相比其他科幻电影吸引用户的概率更大。在此,推荐模型需要捕捉的就是潜藏在电影个体下的演员特征,其能够在一定程度上反映用户的兴趣。因此,如何从更细的粒度捕捉每个交互物品的特征,并从中推断出用户的兴趣,成为了一个亟待解决的问题。

为解决上述两个问题,本文提出了一种基于会话的新型推荐模型,即基于时序推理的分层会话感知推荐模型(Temporal Reasoning based Hierarchical Session Perception Model, TRHSR)。该模型的核心思路是:一方面,借助关系RNN模型<sup>[6]</sup>,通过有选择地保留和利用物品间的依赖关系,赋予模型更灵活地学习物品间交互关系的能力,缓解基于循环神经网络的推荐系统存在的假设过强和忽视集合依赖关系的问题,从而更好地建模会话序列的时序关系,并推测用户的行为模式;另一方面,从会话中的物品和物品特征两个层次进行物品信息的聚合,实现更细粒度的用户兴趣推断。

本文工作的主要贡献包括以下3点:

(1)提出了一种基于关系循环神经网络的会话时序关系建模方法,更灵活地学习和推理物品间的交互关系,以更精确地推测用户的行为模式;

(2)提出了一种新型的从匿名会话中推断用户兴趣的方法,从物品和物品特征两个层次进行特征筛选,实现了更细粒度的用户兴趣推测;

(3)提出了一种基于时序推理的分层会话感知推荐模型,通过更好地建模会话的时序关系和推测用户的兴趣,来提高推荐模型的预测能力。应用于不同公共数据集的实验结果证明了所提模型的有效性。

## 2 相关工作

基于会话的推荐是一个典型的推荐系统应用场景,其基于匿名会话中用户对物品的隐式反馈来预测下一个可能被点击的物品。本节主要介绍基于会话的推荐系统在近年来的研究进展。

基于会话的早期推荐系统的工作主要集中于发掘物品之间的关系,如物品的点击转移概率和共现关系。例如,基于马尔可夫链<sup>[7]</sup>的方法致力于挖掘物品之间的转移关系,假定下一时刻的交互物品仅由当前时刻的交互物品决定,其计算所有已知物品间的转移概率,并根据目标会话中的最后一个交互物品利用转移概率进行推荐。ItemKNN<sup>[8]</sup>方法致力于利用物品间的共现关系,依据所有已知会话中物品的共现频率来计算物品之间的相似度,并根据目标会话中的最后一个交互物品来推荐与其最相似的K个物品。SessionKNN<sup>[9]</sup>方法则为目标会话计算出最相似的邻居会话集合,并将该集合中出现次数最多的K个物品作为推荐物品。但是,这些模型的表达能力有限,无法建模会话中的物品之间复杂的依赖关系。

为了解决这个问题,最近的研究工作利用神经网络来学习物品之间复杂的交互关系。例如,Hidasi等<sup>[1]</sup>将循环神经网络用于基于会话的推荐,并将下一个物品的推荐视为时间序列预测问题,并提出了GRU4Rec模型。为了提高训练的效率,GRU4Rec采用了两种策略来加快训练速度:一方面拼接会话,通过批处理进行并行训练;另一方面,在模型进行损失函数计算时,采取了负采样的方式,减少了计算资源的消耗。Tan等<sup>[10]</sup>对GRU4Rec模型进行了改进,提出了GRU4Rec+模型。具体而言,其针对GRU4Rec模型提出了3条优化规则,包括数据增强、模型预训练和输出层损失函数改进。Hidasi等<sup>[11]</sup>在GRU4Rec的基础上,针对循环神经网络的特性,对损失函数进行优化,通过改变采样策略来提升GRU4Rec的性能。Veronika等<sup>[12]</sup>基于“用户在某物品上的停留时间越长,则对该物品越感兴趣”的假设,提出对用户会在会话中在物品上的停留时间长短进行建模,将用户停留时间融入GRU4Rec框架中。Ren等<sup>[13]</sup>提出在基于会话的推荐中显式地建模用户的重复消费行为,从用户的历史记录中选择合适的物品,并在恰当的时间重复推荐给用户。Li等<sup>[2]</sup>提出通过一种注意力机制来另外捕获目标会话中用户的主要意图,从而改进了GRU4Rec+模型。Liu等<sup>[5]</sup>则强调了短期记忆的优先级,其应用注意力网络对会话建模,提高了目标会话中最后一个交互物品的重要性。Hu等<sup>[14]</sup>提出了一种浅层神经网络结构,通过计算上下文物品之间的相对距离来捕获物品之间的关联性。在最近的研究中,Wu等<sup>[15]</sup>将图神经网络引入到基于会话的推荐中,并提出了SR-GNN模型。SR-GNN模型将单个会话建模为有向图,并利用图神经网络学习会话中物品之间复杂的依赖关系。然而,SR-GNN忽略了对会话中的时序关系进行建模。

本文提出的模型与上述工作的主要区别在于,本文利用




图2 TRHSR模型示意图  
Fig. 2 Illustration of TRHSR model

对于一个特定的待预测目标会话 $\{v_1, v_3, v_2, v_4\}$ ,会话序列中的物品作为TRM模块每个时间步的输入,在不同时间步之间进行时序推理,学习目标会话的时序关系,并从中建模用户的行为模式。然后,HGM模块从物品和物品特征两个层次分层建模物品,捕捉用户兴趣。最后,PM模块综合考虑目标会话中的行为模式和用户兴趣,并针对候选物品集中的每个物品预测交互概率。

### 3.3 时序推理模块

尽管当前基于RNN的模型在SRS中取得了较好的性能,但由于受限于RNN的超强假设问题,其可能学习到错误的依赖关系,并且RNN无法建模会话中的协作依赖项,因此TRM拟在时序建模的过程中引入关系推理的机制,赋予神经网络更灵活的学习物品间交互关系的能力,以学习到会话中

时序推理机制,更灵活地学习目标会话中物品之间的依赖关系,以获取整个会话的时序关系,从而能够更准确地推断用户的行为模式;此外,通过从物品和物品特征两个层面进行特征筛选,能提取到粒度更细的用户兴趣,从而提高推荐系统的性能。

## 3 基于时序推理的分层会话感知模型

本节主要介绍了模型的基本定义、整个模型的流程、3个主要模块的建模过程。

### 3.1 问题描述

基于会话的推荐问题定义为:在缺失用户配置文件和历史交互的情况下,仅仅依赖目标会话中匿名的交互序列来预测目标会话中下一个可能被用户点击的物品。基于会话的推荐问题的公式化描述如下。

用 $V = \{v_1, v_2, \dots, v_{|v|}\}$ 表示所有会话中出现过的物品集合。假设全体历史会话集合为 $S, S = \{s_1, s_2, \dots, s_{|s|}\}$ ,其中每个具体的会话表示一串用户交互的物品。

模型的目标是,通过对历史会话的学习,在给定某目标会话 $s_i = \{v_1, v_2, \dots, v_i\}$ 时,预测下一个可能点击的物品(即 $v_{i+1}$ )。具体而言,模型会生成一个覆盖所有候选物品的排序列表, $\hat{y} = \{\hat{y}_1, \hat{y}_2, \dots, \hat{y}_{|v|}\}$ 表示所有物品的预测概率,其中 $\hat{y}_i$ 对应物品 $v_i$ 的推荐分数,选择 $\hat{y}$ 中得分最大的 $N$ 个物品作为推荐结果。

### 3.2 模型概览

TRHSR模型主要由3个模块构成,即时序推理模块(Temporal Reasoning Module, TRM)、分层门控模块(Hierarchical Gating Module, HGM)以及预测模块(Predicting Module, PM),如图2所示。

更精确的用户行为模式。

具体而言,TRM通过集成关系记忆内核<sup>[6]</sup>,在循环神经网络的内部考虑存储和检索信息的同时进行显式的记忆交互,使模型具备信息推理的能力。

为了阐述记忆交互的具体形式,假设记忆矩阵为 $M$ ,并用其中每行 $m_j$ 代表一个被划分的记忆槽,TRM通过多头注意力机制<sup>[16]</sup>完成不同记忆槽之间的交互,即每一个记忆槽根据与其余记忆槽之间的相关性,选择性地更新自身内容。对于记忆矩阵 $M$ 中的每一个记忆槽,应用简单的线性投影函数构建查询矩阵( $Q = MW^q$ )、关键矩阵( $K = MW^k$ )和价值矩阵( $V = MW^v$ )。接下来,利用查询矩阵和关键矩阵计算注意力系数权重,并应用该权重对价值矩阵计算加权平均值,公式如下:

$$\tilde{\mathbf{M}} = \text{softmax}\left(\frac{\mathbf{M}\mathbf{W}^q(\mathbf{M}\mathbf{W}^k)^\top}{\sqrt{d_k}}\right)\mathbf{M}\mathbf{W}^v \quad (1)$$

其中,  $d_k$  为缩放因子的关键向量的维数,  $\mathbf{W}^q, \mathbf{W}^k, \mathbf{W}^v \in \mathbb{R}^{d \times d}$  为权重矩阵,  $\tilde{\mathbf{M}}$  即为原记忆矩阵的更新矩阵, 通过记忆矩阵的更新, 记忆槽之间的信息进行了关系融合和更新。记忆矩阵的更新过程如图 3 所示。




图 3 记忆矩阵更新过程

Fig. 3 Update process of memory matrix

为了提高注意力机制的非线性表达能力, 在此处引入多头注意力机制<sup>[16]</sup>, 以允许模型在不同的表示子空间中学习到相关的信息。多头注意力机制将原始的记忆矩阵分为  $h$  组多头, 使用不同的参数矩阵对每一组多头中的记忆进行线性映射, 得到  $h$  组不同的查询矩阵、关键矩阵和价值矩阵, 随后对每一组多头中的矩阵使用注意力操作进行聚合。例如, 假设对记忆矩阵  $\mathbf{M} \in \mathbb{R}^{N \times F}$  使用两个多头, 则对两个多头分别进行注意力操作后, 得到子记忆矩阵  $\tilde{\mathbf{M}}_1 \in \mathbb{R}^{N \times F/2}$  和  $\tilde{\mathbf{M}}_2 \in \mathbb{R}^{N \times F/2}$ , 将子记忆矩阵拼接, 即得到更新的记忆矩阵  $\tilde{\mathbf{M}} \in \mathbb{R}^{N \times F}$ 。

在神经网络的每个时间步中, 网络将对当前时刻的输入状态和历史状态进行融合。TRM 将式(2)稍作修改, 便能将新的输入状态融合到历史状态中:

$$\tilde{\mathbf{M}} = \text{softmax}\left(\frac{\mathbf{M}\mathbf{W}^q([\mathbf{M}; \mathbf{x}]\mathbf{W}^k)^\top}{\sqrt{d_k}}\right)[\mathbf{M}; \mathbf{x}]\mathbf{W}^v \quad (2)$$

其中,  $\mathbf{x}$  表示新的输入状态,  $[\mathbf{M}; \mathbf{x}]$  表示将  $\mathbf{M}$  和  $\mathbf{x}$  进行拼接。注意此处输入  $\mathbf{M}$  和输出  $\tilde{\mathbf{M}}$  的维度一致。由于特征之间进行了更充分的交互和选择性的保留, 模型具备了学习划分和对比信息能力的结构, 隐式地表现出了某种形式的关系推理。

由于记忆矩阵的形状在更新过程中维持不变, 因此可以通过先随机初始化  $\mathbf{M}$ , 再对  $\tilde{\mathbf{M}}$  进行每个时间步的更新来循环迭代, 这样的循环特性使得关系记忆内核可以嵌入到 2D-LSTM 的隐层中, 公式如下:

$$s_{i,t} = (\mathbf{h}_{i,t-1}, \mathbf{m}_{i,t-1}) \quad (3)$$

$$\mathbf{f}_{i,t} = \mathbf{W}^f \mathbf{x}_t + \mathbf{U}^f \mathbf{h}_{i,t-1} + \mathbf{b}^f \quad (4)$$

$$\mathbf{i}_{i,t} = \mathbf{W}^i \mathbf{x}_t + \mathbf{U}^i \mathbf{h}_{i,t-1} + \mathbf{b}^i \quad (5)$$

$$\mathbf{o}_{i,t} = \mathbf{W}^o \mathbf{x}_t + \mathbf{U}^o \mathbf{h}_{i,t-1} + \mathbf{b}^o \quad (6)$$

$$\mathbf{m}_{i,t} = \sigma(\mathbf{f}_{i,t} + \tilde{\mathbf{b}}^f) \circ \mathbf{m}_{i,t-1} + \sigma(\mathbf{i}_{i,t}) \circ \mathbf{g}_\varphi(\tilde{\mathbf{m}}_{i,t}) \quad (7)$$

$$\mathbf{h}_{i,t} = \sigma(\mathbf{o}_{i,t}) \circ \tanh(\mathbf{m}_{i,t}) \quad (8)$$

$$s_{i,t+1} = (\mathbf{h}_{i,t}, \mathbf{m}_{i,t}) \quad (9)$$

其中,  $\mathbf{m}_{i,t}$  表示记忆矩阵  $\mathbf{M}$  第  $i$  行的第  $t$  个时刻的状态,  $\mathbf{g}_\varphi(\cdot)$  表示对典型 LSTM 结构的修改,  $\mathbf{f}_{i,t}, \mathbf{i}_{i,t}, \mathbf{o}_{i,t} \in \mathbb{R}^d$  分别表示典型 LSTM 结构的遗忘门、输入门和输出门, 分别用于控制是否遗忘记忆中的信息、是否更新来自当前输入的信息、是否将记忆中的信息传递给输出。  $\sigma$  表示 sigmoid 函数,

$\tanh$  表示双曲正切函数,  $d$  是物品表示向量和 LSTM 隐藏层的维数。  $\mathbf{W}^f, \mathbf{U}^f, \mathbf{W}^i, \mathbf{U}^i, \mathbf{W}^o, \mathbf{U}^o \in \mathbb{R}^{d \times d}$  为权重矩阵;  $\mathbf{b}^f, \mathbf{b}^i, \mathbf{b}^o, \tilde{\mathbf{b}}^f \in \mathbb{R}^d$  为偏置向量。因此, 可以利用集成了关系记忆内核的循环神经网络(即关系 RNN)对目标会话进行建模。首先, 将目标会话  $s_t = \{v_1, v_2, \dots, v_t\}$  中的每个物品映射为一个低维嵌入向量:

$$\mathbf{X} = \langle \mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_t \rangle, \mathbf{x}_t \in \mathbb{R}^d \quad (10)$$

TRM 将会话中的物品向量按时序顺序作为上述关系 RNN 结构的输入, 并将关系 RNN 的每个隐层矩阵压缩为状态向量, 即可得到隐向量作为输出:

$$\mathbf{H} = \langle \mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_t \rangle, \mathbf{h}_t \in \mathbb{R}^d \quad (11)$$

其中, 最后一个时间步的输出向量作为目标会话对应的用户行为模式, 其捕捉了用户的时序动作顺序的整体性, 即  $\mathbf{c}_t^b = \mathbf{h}_t$ 。

基于上述描述, TRM 模块可以为每个目标会话学习对应的用户行为模式。

### 3.4 分层门控模块

由于基于会话的推荐存在着用户冷启动<sup>[17]</sup>的问题, 匿名会话往往由有限个隐式反馈构成, 在这种情况下, 从数量有限的隐式反馈中准确地推测用户的兴趣对推荐系统而言尤为重要。立足于此, 分层门控模块(HGM)在时序推理模块的基础上, 从物品个体和物品特征两个层次, 充分考虑了物品内蕴含的多样性信息, 从而捕捉到目标会话用户更细粒度的兴趣。

图 4 简要地展示了特征门和个体门的含义。假设每个圆角矩形表示一个物品特征, 那么在特征门中, 灰色部分对应的部分特征隐向量被一定程度地忽略; 而在个体门中, 通过灰色的颜色深浅来表示该物品特征整体的重要程度。具体而言, 颜色越深表示该物品越重要。




图 4 特征门和个体门示例

Fig. 4 Illustrations of feature gate and instance gate

#### 3.4.1 特征层次建模

有不少工作试图利用注意力机制从那些真正与下一步交互物品预测相关的信息中选择性地保留和利用信息, 并将其表示为用户兴趣。然而之前的注意力模型往往并未考虑不同物品特征的特定部分, 忽略了物品内蕴含的丰富的多样性信息, 这导致无法在当前会话中捕捉到充分的用户兴趣。因此, 受文献[18]的启发, 本文提出了一个用于匿名会话的可学习的特征选通门, 筛选出显著特征以辅助建模用户的兴趣。

$$\mathbf{H}_F = \mathbf{H} \otimes \sigma(\mathbf{W}_{f1} \cdot \mathbf{H} + \mathbf{W}_{f2} \mathbf{h}_t + \mathbf{W}_{f3} \mathbf{h}_s + \mathbf{b}_f) \quad (12)$$

其中,  $\mathbf{H}$  表示目标会话的所有物品嵌入向量经过 TRM 后输出的隐向量矩阵, 假设目标会话由  $t$  个物品构成, 则  $\mathbf{H} \in \mathbb{R}^{t \times d}$ 。  $\mathbf{h}_t$  表示目标会话中最后一个交互物品的隐向量,  $\mathbf{h}_s$  为目标会话中所有物品隐向量的平均值,  $\mathbf{W}_{f1} \in \mathbb{R}^{d \times d}$ ,  $\mathbf{W}_{f2} \in \mathbb{R}^{d \times d}$ ,  $\mathbf{W}_{f3} \in \mathbb{R}^{d \times d}$  和  $\mathbf{b}_f \in \mathbb{R}^d$  分别为可学习的权重矩阵和偏

置向量,  $\otimes$  表示矩阵之间的哈达玛积。基于上述操作, 显著特征被放大, 并被传递到下游以帮助推断用户兴趣。

### 3.4.2 个体层次建模

为了更进一步地聚合目标会话中所有物品的显著特征, 同时筛选出更有价值的点击物品, 去除序列中的噪声, 本文基于注意力机制对经过特征选通门得到的隐向量矩阵进行聚合:

$$\alpha_i = q(\mathbf{h}_{iF}, \mathbf{h}_s) = \mathbf{v}^T \sigma(\mathbf{W}_{11} \mathbf{h}_{iF} + \mathbf{W}_{12} \mathbf{h}_s) \quad (13)$$

$$\mathbf{c}_i^j = \sum_{i=1}^I \alpha_i \mathbf{h}_{iF} \quad (14)$$

其中,  $\alpha$  是一个加权因子, 代表会话中哪些物品应该被强调或者忽视,  $\mathbf{h}_{iF}$  表示隐向量矩阵  $\mathbf{H}_F$  中第  $i$  个物品的隐向量,  $\mathbf{h}_s$  为目标会话中所有物品隐向量的平均值,  $\mathbf{W}_{11}, \mathbf{W}_{12} \in \mathbb{R}^{d \times d}$  是可学习的权重矩阵,  $\mathbf{v} \in \mathbb{R}^d$  是可学习的向量。通过特征和个体两个层次的建模, 重要的特征和更相关的物品的影响力被放大, 而无关的噪声特征和物品则被选择性地忽略, 从而可以更好地反映目标会话中的用户兴趣。

### 3.5 预测模块

最终的用户表示由用户行为模式向量  $\mathbf{c}_i^b$  和用户兴趣向量  $\mathbf{c}_i^j$  联合表示:

$$\mathbf{c}_i = [\mathbf{c}_i^b; \mathbf{c}_i^j] \quad (15)$$

其中,  $[\cdot]$  表示两个向量的拼接操作。

用户对每个物品的预测得分由用户表示和物品表示间的双线性相似度函数计算得到, 即:

$$\hat{z}_i = \mathbf{x}_i^T \mathbf{B} \mathbf{c}_i \quad (16)$$

其中,  $\mathbf{x}_i$  表示待预测物品  $i$  的低维嵌入向量。  $\mathbf{B} \in \mathbb{R}^{d \times 2d}$  为可学习的权重矩阵, 由于不同待预测物品是共享的,  $d$  既是物品嵌入向量的维度, 也是用户行为模式/用户兴趣向量的维度。

最终的目标函数定义为物品的预测得分和实际用户点击的物品的独热编码之间的交叉熵:

$$L(\hat{\mathbf{y}}) = - \sum_{i=1}^m y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i) \quad (17)$$

其中,  $\hat{\mathbf{y}} = \text{softmax}(\hat{\mathbf{z}})$ ,  $\hat{\mathbf{y}} = \{\hat{y}_1, \hat{y}_2, \dots, \hat{y}_m\}$ ,  $\mathbf{y} = \{y_1, y_2, \dots, y_m\}$  表示实际点击物品的独热编码向量。

## 4 实验结果与分析

### 4.1 数据集

本文在两个现实世界的数据集 (Diginetica 和 Retailrocket) 上进行所有实验。其中, Diginetica 来自 2016 年 CIKM 杯; Retailrocket 则来自一家电子商务公司, 这个数据集包含 6 个月的用户浏览记录。类似于文献[19], 对于 Retailrocket 数据集, 我们手动地将历史行为数据以 30 min 的间隔划分成多段会话。类似于文献[2]和文献[5], 长度为 1 的会话被过滤掉, 出现次数小于 5 次以及只出现在测试集中的物品也同样被过滤掉。此外, 根据 Tan 等[10] 的研究, 本文对实验数据进行了扩充, 对于给定会话  $s_i^j = \{v_1, v_2, \dots, v_t\}$ , 生成子序列  $\{[v_1], v_2\}, \{[v_1, v_2], v_3\}, \dots$ , 以及  $\{[v_1, v_2, \dots, v_{t-1}], v_t\}$ , 将每个子序列括号内的物品作为输入数据, 剩余一项作为标签数据 (即该子会话下一次点击的物品)。数据集的统计信息如表 1 所列。

表 1 数据集的统计信息

Table 1 Statistic of datasets

Dataset	Diginetica	Retailrocket
Train Sessions	719 470	264 453
Test Sessions	60 858	35 762
Clicks	982 961	413 648
Items	43 097	24 095
Avg. len	5.12	6.68

### 4.2 评价指标

在评测模型性能时, 本文采用 HR@K 和 MRR@K 评价指标[19]。

MRR@K 平均倒数排名 (mean reciprocal rank), 如果某样本推荐结果的排名不在 top-K 范围内, 则将其 MRR@K 值设置为 0, 否则保持该排名值, 用于下列公式进行平均计算。MRR@K 的值位于  $[0, 1]$  区间内, 其值越大, 表明推荐的命中率越高。

$$MRR@K = \frac{1}{N} \sum_{t \in V, Rank(t) < K} \frac{1}{Rank(t)} \quad (18)$$

HR@K 表示在推荐结果排名前 K 的推荐物品中正确答案数量占所有测试集样本数量的比例, 定义为:

$$HR@K = \frac{NumberOfHits@K}{N} \quad (19)$$

### 4.3 对比模型

为了验证所提 TRHSR 模型的性能, 本文采用的对比模型如下。

(1) POP[1]: 总是向用户推荐训练集中最受欢迎和流行的物品。这是一个很简单的基线模型, 但在特定情况下可以获得很好的效果。

(2) S-POP[1]: 推荐目标会话中最受欢迎的物品。

(3) GRU4Rec[1]: 由 GRU 单元组成的基于 RNN 的会话推荐模型, 利用小批量并行训练加快训练速度, 在模型进行损失函数计算时, 通过负采样来减少计算资源的消耗。

(4) NARM[2]: 基于 RNN 的会话推荐模型, 利用注意力机制从隐藏状态获得用户的主要兴趣, 并将其与用户的序列行为结合起来作为会话的最终表征, 从而生成推荐。

(5) STAMP[5]: 该模型引入注意力机制同时考虑用户的长期兴趣和短期兴趣, 并通过提高短期兴趣的重要性来缓解兴趣漂移对推荐模型的影响。

(6) SR-GNN[15]: 该模型忽略了会话中的时序关系, 将单个会话建模为有向图, 并利用图神经网络来学习会话中物品之间复杂的依赖关系。

(7) TRHSR: 本文提出的基于时序推理的分层会话感知推荐模型。

(8) TRHSR-R: TRHSR 模型的变体, 不使用关系 RNN 进行序列建模, 而是使用 GRU 结构。

(9) TRHSR-F: TRHSR 模型的变体, 在使用关系 RNN 进行序列建模后对得到的隐向量进行平均池化, 不使用分层门控模块。

### 4.4 实验设置

本文提出的 TRHSR 模型的超参数通过网格参数寻优法进行选择。根据在验证集上的调参结果, 使用的超参数如下: 物品嵌入向量的维度为 100, 初始学习率为 0.001, 优化器为 Adam, 学习率衰减率为 0.96, 训练批量为 256, 迭代次数为

30. 所有权重矩阵均采用服从正态分布的随机数初始化。

#### 4.5 实验结果与分析

##### 4.5.1 整体实验结果的分析

将 TRHSR 模型与对比模型进行比较发现, TRHSR 的性能达到了最优, 如表 2 所列。

表 2 Diginetica 和 Retailrocket 数据集上的实验结果

Table 2 Experimental results on Diginetica and Retailrocket

Model	Diginetica		Retailrocket	
	MRR@20	HR@20	MRR@20	HR@20
POP	0.24	0.96	0.32	1.24
S-POP	14.60	21.11	32.04	40.48
GRU4Rec	24.93	57.95	21.60	49.65
NARM	27.35	62.58	34.07	61.79
STAMP	27.38	62.03	33.10	61.08
SR-GNN	27.54	63.09	34.22	62.34
TRHSR	<b>28.30</b>	<b>63.74</b>	<b>35.06</b>	<b>63.45</b>

根据表 2 中的实验结果, 有以下发现:

(1) 基于循环神经网络的模型 (GRU4Rec, NARM, TRHSR) 的表现均优于传统模型, 这证明相比传统模型, 基于循环神经网络的模型更擅长处理会话中的序列信息, 而传统模型的表达能力有限, 无法建模会话中的物品之间复杂的依赖关系。

(2) TRHSR 模型的表现优于所有基于传统循环神经网络的对比模型, 相比最优的对比模型 SR-GNN, 其在两个数据集上的 HR@20 指标分别高出 1.03% 和 1.75%, 其 MRR@20 指标分别高出 2.76% 和 2.45%。由此推断, 通过对建模用户行为模式和推测用户兴趣两个层面的改进, 缓解了对目标会话预测的不确定性, 从而提高了推荐的准确率。

##### 4.5.2 时序推理机制的有效性

为了进一步验证基于时序推理的关系 RNN 模型对会话序列建模的有效性, 本文提出了模型 TRHSR-R 进行对比实验。TRHSR-R 是本文提出的标准模型 TRHSR 的变体, 与 TRHSR 的区别在于, 在序列建模过程中, 其未使用基于时序关系推理的关系 RNN 模型, 而是使用基于传统循环神经网络的 GRU 模型, 其他部分与 TRHSR 保持一致。因此, 通过这两个模型的对比实验, 可以验证关系 RNN 模型在基于会话的推荐系统中的有效性。从表 3 可以看出, TRHSR 模型的表现明显优于 TRHSR-R 模型, 其在两个数据集上的 HR@20 指标分别比 TRHSR-R 高出 2.00% 和 2.59%, 其 MRR@20 指标分别比 TRHSR-R 高出 3.74% 和 3.18%。这表明相比传统的 RNN 结构, 关系 RNN 可以通过选择性地保留和利用物品间的依赖关系, 赋予模型更灵活的学习物品间交互关系的能力, 以缓解基于循环神经网络的推荐系统存在的超强假设问题, 从而更好地推测用户的行为模式。

表 3 时序推理机制的影响

Table 3 Impact of temporal reasoning

Model	Diginetica		Retailrocket	
	MRR@20	HR@20	MRR@20	HR@20
TRHSR-R	27.28	62.49	33.98	61.85
TRHSR	<b>28.30</b>	<b>63.74</b>	<b>35.06</b>	<b>63.45</b>

##### 4.5.3 特征层次建模的有效性

为了进一步验证在特征和个体两个层次对会话进行建模的有效性, 本文提出了 TRHSR-F 模型进行对比实验。TRHSR-F 模型是 TRHSR 模型的变体, 与 TRHSR 的区别在于其

未进行特征层次建模, 在通过关系 RNN 进行序列建模后直接进行个体层次的建模, 基于注意力机制聚合所有时刻的隐向量得到会话的表示向量。因此, 通过这两个模型的对比实验, 可以验证分层门控模块的有效性。从图 5 可以看出, TRHSR 模型在所有指标上的表现均优于对比模型 TRHSR-F, 这表明特征层次建模可以充分挖掘会话中物品的多样性信息, 捕捉更细粒度的用户兴趣。

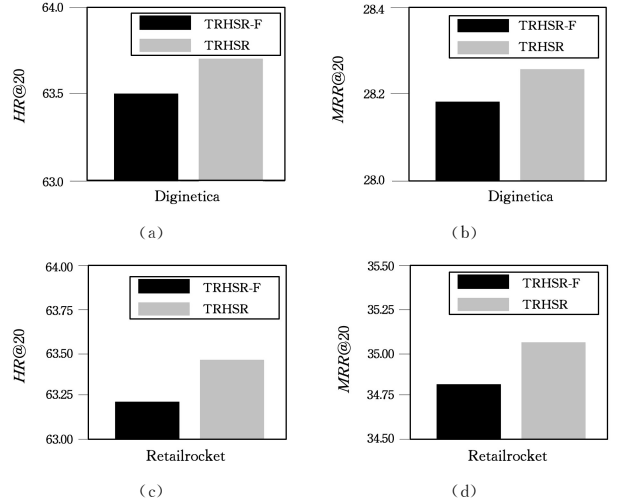


图 5 分层建模机制的有效性

Fig. 5 Effectiveness of hierarchical modeling

##### 4.5.4 多头数量对模型效果的影响

为了探究关系 RNN 模型的效果, 本文针对关系 RNN 模型中的重要参数多头数量 (number of heads) 的设置进行了对比实验 (分别设置多头数量为 3, 5, 7, 10, 15, 20)。在多头注意力机制中, 不同的多头针对记忆矩阵的不同列注意力操作, 在不同的子表示空间中学习相关的信息。如图 6 所示, 当多头数量较少时, 模型效果相对较差; 而当多头数量逐渐增加时, 模型效果逐渐变好; 当多头数量大于 10 时, 模型效果只获得微弱的提升甚至下降, 这是因为当多头数量为 10 时, 关系 RNN 模型已经充分挖掘了序列中的信息, 为了平衡模型的表现和计算开销, 本文设置多头数量为 10。

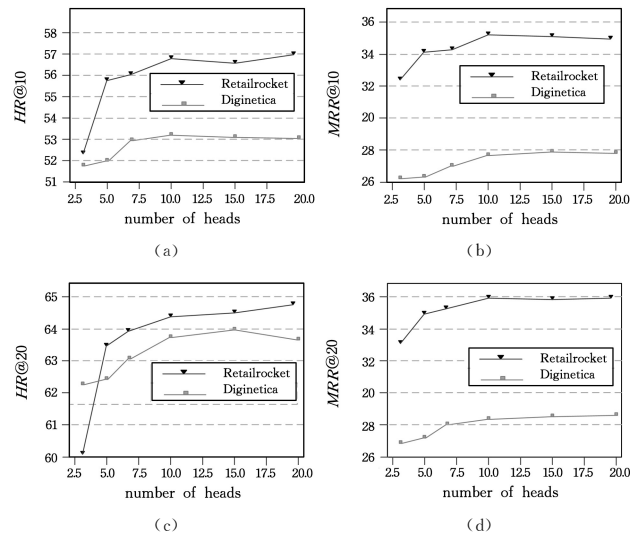


图 6 多头数量对模型的影响

Fig. 6 Impact of number of heads on models

**结束语** 本文提出了一种基于时序推理的分层会话感知模型,并将其应用于基于会话的推荐系统中。该模型利用时序推理机制,建模目标会话中复杂的物品间依赖关系,学习更灵活的会话时序关系;同时,提出了一种从匿名会话中推断用户兴趣的新方法,有选择性地从目标会话中保留和利用真正与下一步预测强相关的物品和物品特征,捕捉相应目标会话中更细粒度的用户兴趣。总体而言,本文为基于会话的推荐任务提供了新的建模角度。在两个公共数据集上,所提模型 TRHSR 均取得了最佳的性能,验证了其有效性。同时,本文对 TRHSR 模型的关键模块的性能进行了对比实验,验证了关键模块算法的有效性。在未来,我们计划更进一步地挖掘各匿名会话之间的协同过滤关系,研究如何在牺牲目标会话特异性的基础上,扩展目标会话中丰富的协同信息,提高推荐系统的预测能力。

### 参考文献

- [1] HIDASI B, KARATZOGLOU A, et al. Session-based recommendations with recurrent neural networks [C] // Proc of the 4th Int Conf on Learning Representations. San Juan, CA: ICLR, 2016.
- [2] LI J, REN P J, CHEN Z M, et al. Neural attentive session-based recommendation [C] // Proc of the 11th ACM Int Conf on Information and Knowledge Management. New York: ACM, 2017: 1419-1428.
- [3] CHO K, MERRIENBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation [C] // Proc of Conf on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2014: 1724-1734.
- [4] WANG S, CAO L, WANG Y, et al. A Survey on Session-based Recommender Systems [J]. arXiv:1902.04864.
- [5] LIU Q, ZENG Y F, MOKHOSI R, et al. STAMP: Short-term attention/ memory priority model for session-based recommendation [C] // Proc of the 24th ACM SIGKDD Int Conf on Knowledge Discovery and Data Mining. New York: ACM, 2018: 1831-1839.
- [6] SANTORO A, FAULKNER R, RAPOSO D, et al. Relational recurrent neural networks [C] // Proc of the 32th Advances in Neural Information Processing Systems. 2018: 7299-7310.
- [7] GU W R, DONG S B, ZENG Z Z. Increasing recommended effectiveness with markov chains and purchase intervals [J]. Neural Computing and Applications, 2014, 25(5): 1153-1162.
- [8] DAVIDSON J, LIEBALD B, LIU J, et al. The YouTube video recommendation system [C] // Proc of the 4th ACM Conference on Recommender Systems. 2010: 293-296.
- [9] JANNACH D, LUDEWIG M. When recurrent neural networks meet the neighborhood for session-based recommendation [C] // Proceedings of the Eleventh ACM Conference on Recommender Systems. 2017: 306-310.
- [10] TAN Y K, XU X, LIU Y, et al. Improved Recurrent Neural Networks for Session-based Recommendations [C] // Proc of the 1st Workshop on Deep Learning for Recommender Systems. New York: ACM, 2016: 17-22.
- [11] HIDASI B, KARATZOGLOU A. Recurrent Neural Networks with Top-k Gains for Session-based Recommendations [C] // Conference on Information and Knowledge Management. 2018: 843-852.
- [12] VERONIKA B, TSVI K. Incorporating dwell time in session-based recommendation with recurrent neural network [C] // Proc of Rec Temp Workshop co-located with ACM RecSys. 2017: 256-260.
- [13] REN P, CHEN Z, LI J, et al. RepeatNet: A Repeat Aware Neural Recommendation Machine for Session-based Recommendation [C] // National Conference on Artificial Intelligence. 2019: 4806-4813.
- [14] HU L, CAO L B, WANG S J, et al. Diversifying personalized recommendation with user-session context [C] // Proc of the 26th Int Joint Conf on Artificial Intelligence. Menlo Park, CA: AAAI, 2017: 1858-1864.
- [15] WU S, TANG Y, ZHU Y, et al. Session-based recommendation with graph neural networks [C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2019: 346-353.
- [16] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C] // Proc of the 31th Advances in Neural Information Processing Systems. 2017: 5998-6008.
- [17] SARWAR B M, KARYPIS G, KONSTAN J A, et al. Item-based collaborative filtering recommendation algorithms [C] // The Web Conference. 2001: 285-295.
- [18] MA C, KANG P, LIU X. Hierarchical gating networks for sequential recommendation [C] // Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2019: 825-833.
- [19] MALTE L, DIETMAR J. Evaluation of session-based recommendation algorithms [J]. User Modeling and User-Adapted Interaction, 2018, 28(4/5): 331-390.



**LUO Peng-yu**, born in 1996, master student. His main research interests include data mining, recommendation system and machine learning.



**WU Le**, born in 1988, Ph.D, associate professor. Her main research interests include recommendation systems, data mining and social network analysis.