



计算机科学

COMPUTER SCIENCE

基于微观行为的自适应多注意力会话推荐

乔晶晶, 王莉

引用本文

乔晶晶, 王莉. 基于微观行为的自适应多注意力会话推荐[J]. 计算机科学, 2022, 49(11): 117-125.

QIAO Jing-jing, WANG Li. Modeling User Micro-Behavior via Adaptive Multi-Attention Network for Session-based Recommendation[J]. Computer Science, 2022, 49(11): 117-125.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于图卷积神经网络的文本分类方法研究综述](#)

Review of Text Classification Methods Based on Graph Convolutional Network

计算机科学, 2022, 49(8): 205-216. <https://doi.org/10.11896/jsjcx.210800064>

[基于多智能体强化学习的端到端合作的自适应奖励方法](#)

Adaptive Reward Method for End-to-End Cooperation Based on Multi-agent Reinforcement Learning

计算机科学, 2022, 49(8): 247-256. <https://doi.org/10.11896/jsjcx.210700100>

[增强列表信息和用户兴趣的个性化新闻推荐算法](#)

Personalized News Recommendation Algorithm with Enhanced List Information and User Interests

计算机科学, 2022, 49(6): 142-148. <https://doi.org/10.11896/jsjcx.210400173>

[语义增强的完全不平衡标签网络表示学习算法](#)

Semantic Information Enhanced Network Embedding with Completely Imbalanced Labels

计算机科学, 2022, 49(11): 109-116. <https://doi.org/10.11896/jsjcx.210900101>

[时空图注意力网络在交叉口车辆轨迹预测的应用](#)

Application of Spatial-Temporal Graph Attention Networks in Trajectory Prediction for Vehicles at Intersections

计算机科学, 2021, 48(6A): 334-341. <https://doi.org/10.11896/jsjcx.200800066>

基于微观行为的自适应多注意力会话推荐

乔晶晶¹ 王莉²

1 太原理工大学信息与计算机学院 山西 晋中 030600

2 太原理工大学大数据学院 山西 晋中 030600

(2389737257@qq.com)

摘要 会话推荐(Session-based Recommendation, SR)旨在根据短期会话信息推荐用户偏好的下一个物品,它不需要用户的配置文件和长期历史信息,具有广阔的应用前景。现有的SR模型通常关注用户点击行为或仅利用某单一类型的行为数据,忽略了用户点击行为的具体语义,如商品浏览、商品收藏、添加到购物车、购买等。这些不同语义的行为被称为微观行为,能够从微观层面反映用户在购物过程中意图的转换以及决策过程,为改善推荐效果提供了有价值的信息。文中提出了一种基于微观行为的自适应多注意力会话推荐模型(Adaptive Multi-Attention Network, AMAN)。首先,将微观行为组成的会话序列建模为异构有向图,然后建立3个组件进行会话推荐:有向图注意力网络(Directed Graph Attention network, DGAT)从物品级学习物品表征,自适应捕获具有相同微观操作的物品间的关联性;操作级异构图注意力网络(Operation-level Heterogeneous Graph Attention network, OHGAT)从操作级学习物品表征,自适应捕获具有不同微观操作的物品间的关联性;微观行为协同注意力网络(Micro-Behavior Co-Attention network, MBCAT)学习微观行为序列表征,自适应捕获不同微观行为序列间的依赖性。在Yoochoose, Taobao14和Taobao15这3个数据集上的实验结果表明,所提方法优于基线模型。

关键词 会话推荐;微观行为;异构有向图;注意力网络

中图法分类号 TP391

Modeling User Micro-Behavior via Adaptive Multi-Attention Network for Session-based Recommendation

QIAO Jing-jing¹ and WANG Li²

1 College of Information and Computer, Taiyuan University of Technology, Jinzhong, Shanxi 030600, China

2 College of Data Science, Taiyuan University of Technology, Jinzhong, Shanxi 030600, China

Abstract Session-based recommendation (SR) aims to recommend the next item that matches the user's preferences based on their short-term session information. It does not need user's profile and long-term historical information and has a broad application prospect. Existing SR models usually focus on user click behavior or only use a single type of behavior data, ignoring the specific semantics of user click behavior, such as browsing, collecting, carting, purchasing, and so on. These behaviors with different semantics are called micro-behavior, which reflects the transformation of user intention and decision-making process in the shopping process from the micro level and will provide valuable information for improving the recommendation effect. Therefore, an adaptive multi-attention network (AMAN) based on user micro-behavior is proposed for session-based recommendation. First, we model the sequence of micro-behavior as heterogeneous directed graph, and then build three components for session-based recommendation. Directed graph attention network (DGAT) learns item representation from the item level and adaptively captures the associations between items with the same micro-operation. Operation-level heterogeneous graph attention network (OHGAT) learns item representation at the operation-level and adaptively captures the associations between items with different micro-operation. Micro-behavior co-attention network (MBCAT) learns the representation of micro-behavior sequences and adaptively captures the dependencies between different micro-behavior sequences. Experimental results on Yoochoose, Taobao14 and Taobao15 datasets show that AMAN outperforms the state-of-the-art baselines.

Keywords Session-based recommendation, Micro-behavior, Heterogeneous directed graph, Attention network

到稿日期:2021-09-07 返修日期:2021-10-15

基金项目:国家自然科学基金(61872260)

This work was supported by the National Natural Science Foundation of China(61872260).

通信作者:王莉(wangli@tyut.edu.cn)

1 引言

在互联网信息快速增长的时代,推荐系统成为缓解信息过载、满足个性化需求的重要工具。传统的推荐算法主要依靠用户配置文件和长期历史行为进行推荐^[1],然而,在电商场景中,存在用户配置文件不可获取(如未登录用户)的场景,并且配置文件和长期历史行为只能反映用户的一般兴趣,但是实际上用户兴趣和意图会随着时间的推移而动态变化。会话推荐(SR)旨在仅根据会话中的短期历史行为推荐用户偏好的下一个物品,在许多在线应用(如电子商务、流媒体等)中具有很高的实用价值,越来越受到学术界和工业界的关注^[2-3]。

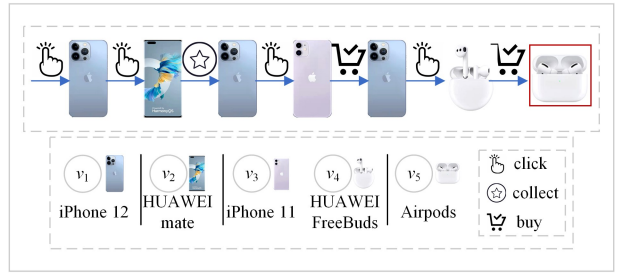
现有的SR模型^[4-8]大多仅利用了用户的点击信息或某单一类型的行为数据,不能全面分析并准确捕获用户兴趣,从而影响了推荐效果。例如,仅基于购买行为建立的SR模型无法对没有历史购买记录的用户进行有效推荐。在电子商务等现实应用中,浏览、收藏、加入购物车、购买等微观行为往往相伴而生,共同反映用户的意图和决策过程,充分利用这些微观行为能够改善推荐效果。

近年来,一些结合用户微观行为进行会话推荐的研究方法被提出。Wang等^[9]提出了MGNN-SPred,首先基于点击和购买两种微观行为序列构建全局物品多关系图,利用多关系图神经网络(Multi-relational Graph Neural Network, MGNN)学习全局物品表征,然后通过平均池化得到当前会话的目标行为序列表征和辅助行为序列表征,最后采用门控机制融合两种行为序列表征,用于提升目标行为场景的推荐性能。MGNN根据节点的类型和方向聚合邻居节点信息,每个节点包含“target-forward”“target-backward”“auxiliary-forward”和“auxiliary-backward”4种邻居节点类型,通过平均池化聚合相同类型的邻居节点信息,通过求和操作聚合不同类型的邻居节点信息。Meng等^[10]提出融合微观行为和物品知识的会话推荐模型MKM-SR,根据物品和微观操作的特点,采用不同的学习机制学习物品表征和操作表征,使用门控图神经网络(Gated Graph Neural Network, GGNN)建模会话中物品间的复杂依赖性,使用门控递归单元(Gated Recurrent Unit, GRU)建模会话中微观操作的顺序依赖性。

相比传统方法,上述方法取得了显著改进,但仍存在以下局限性。

(1)没有充分考虑具有不同微观操作的物品间的关联性。如图1所示,微观行为⟨Airpods; purchase⟩受⟨iPhone 12; purchase⟩的影响,它们的微观操作类型相同。微观行为⟨Airpods; purchase⟩也受⟨HUAWEI FreeBuds; click⟩的影响,它们具有不同的微观操作类型。若忽略具有不同微观操作的物品间的关联性,则可能继续推荐手机。但实际上,正确的推荐策略应该是向用户推荐手机配件而不是手机,配件的品牌应该是苹果而不是华为。

(2)未充分利用不同微观行为序列间的依赖性。不同类型的微观行为序列间存在复杂的依赖关系,如购买行为、收藏行为和点击行为反映了用户意图和偏好的程度不同,而且相互影响,充分挖掘并利用这种关系可以提高推荐性能。



注:红框表示下一个要推荐的物品

图1 微观行为举例(电子版为彩图)

Fig. 1 Example of micro-behaviors

针对上述问题,本文提出了一种融合微观行为的自适应多注意力会话推荐模型。首先,将会话序列建模为一个异构有向图;其次,建立一个有向图注意力网络,从物品级学习物品表征,自适应捕获具有相同微观操作的物品间的关联性;再次,建立操作级异构图注意力网络,从操作级学习物品表征,自适应捕获具有不同微观操作的物品间的关联性;然后,建立微观行为协同注意力网络,学习微观行为序列表征,自适应捕获不同微观行为序列间的依赖性;最后,根据目标行为序列表征、辅助行为序列表征和物品表征预测购买下一个物品的概率。

本文的主要贡献为:1)引入会话中用户行为的语义信息,将基于微观行为的会话序列建模为异构有向图,提出了基于微观行为的自适应会话推荐模型(AMAN);2)提出基于有向图注意力网络的物品级物品表征方法和基于异构图的操作级物品表征方法,自适应捕获具有相同和不同微观操作的物品间的关联性;3)提出微观行为协同注意力网络(MBCAT)学习微观行为序列表征,自适应捕获不同微观行为序列间的依赖性;4)多个数据集上的实验结果表明,本文提出的AMAN模型优于基线模型。

2 相关工作

2.1 会话推荐

基于物品的近邻法^[11]是最早用于会话推荐的方法,会推荐与会话中最后一个物品最相似的物品。考虑到会话中物品之间的顺序依赖性,文献^[12-13]提出了基于马尔可夫链的方法,该方法根据序列中的前几个物品预测下一个物品,当考虑更多的前几个物品时,状态空间不可管理,限制了该方法捕获更高阶的序列模式。目前,深度神经网络已被用于会话推荐,并取得了显著成果。受循环神经网络(Recurrent Neural Network, RNN)在序列建模方面成功应用的启发,研究人员将该技术引入会话推荐任务中。Hidasi等^[4]提出了GRU4REC模型,最早尝试将RNN的变体——门控递归单元(GRU)用于会话推荐,应用多层GRU学习用户顺序行为,并取得了比传统方法更显著的成效。随后,一些研究^[5-6]采用注意力机制建模用户顺序行为依赖关系和主要兴趣,其推荐效果优于基于RNN的模型。Li等^[5]提出了一种编码器-解码器模型NARM,将注意力机制集成到RNN以捕获用户的顺序行为和主要兴趣。Liu等^[6]提出了STAMP模型,从会话序列中学习用户的一般兴趣,并聚焦会话序列的最后一个物品,学习

用户当前兴趣。RNN 在最新的工作中仍然是流行的会话数据建模工具,许多学者修改和改进 RNN 进行会话推荐,如应用数据增强技术^[14]、结合其他模型^[13]、设计适当的目标函数^[16]或融合内容特征^[17-19]等。基于 RNN 的模型仅能对会话序列中的顺序依赖性进行建模,而图神经网络(Graph Neural Network, GNN)可以建模物品间的复杂依赖关系。Wu 等^[7]提出了 SR-GNN 模型,首次使用门控图神经网络(GGNN)建模会话信息,以捕获会话中丰富的结构依赖关系,其性能优于基于 RNN 的模型。与文献^[7]类似, Xu 等^[8]使用 GGNN 提取存在于会话相邻物品上的局部依赖关系,并使用自注意力网络(Self-Attention Network, SAN)捕获会话中远距离物品之间的远程依赖关系。Qiu 等^[20]提出了一种全图神经网络协同建模物品转换模式中的序列模式和潜在模式,利用加权图注意力网络和读出函数分别学习物品表征和会话表征。Liu 等^[21]引入物品的类别属性,构建物品关系图和类别关系图,使用 GGNN 从物品的 id 层面和概念层面建模序列模式。这些研究表明了图神经网络在会话推荐任务中的优秀表现,因此其成为了当前的主要技术。

2.2 基于用户微观行为的会话推荐

从利用的数据特征角度,引入用户微观行为进行会话推荐的研究还处于起步阶段。Le 等^[22]使用孪生 RNN 网络建模点击行为序列和购买行为序列,预测用户下一个可能购买的物品。并根据点击行为序列和购买行为序列的相似程度或参数共享的不同,提出了 3 种孪生 RNN 结构。Wang 等^[9]提出了 MGNN-SPred 模型,首先基于所有会话中的点击和购买两种微观行为序列构建多关系物品图,利用多关系图神经网络 MGNN 学习全局物品表征。平均池化点击行为序列中的物品表征得到点击行为序列表征,平均池化购买行为序列中的物品表征得到购买行为序列表征,采用门控机制将两种行为序列表征相融合,得到用户的一般兴趣,用于下一个物品推荐。Meng 等^[10]尝试将用户微观行为和物品知识融入基于会话推荐的多任务学习中,提出了 MKM-SR 模型,该模型使用 GGNN 对会话的物品序列建模,使用 GRU 对会话的微观操作序列建模。

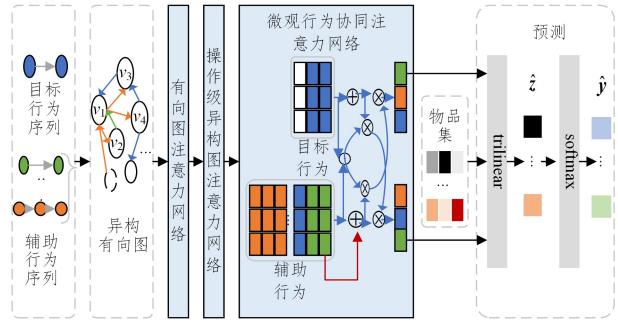
上述研究引入了用户微观行为,一定程度上提升了推荐性能,但是他们未充分考虑不同微观操作中物品间的关联性,以及多种微观行为序列间的依赖性。因此,本文针对物品间的关联性和行为间的依赖性进行建模,提出了一种基于微观行为的自适应会话推荐模型 AMAN。

3 AMAN 模型

3.1 问题描述

设 $V = \{v_1, v_2, \dots, v_{|V|}\}$ 表示物品集; $R = \{r_1, r_2, \dots, r_{|R|}\}$ 表示微观操作集,其中 $|R| \geq 2$,操作集中只有一个目标操作,其余为辅助操作。为方便表述,此处假定 $r_{|R|}$ 为目标操作。设 $S = \{s_1, s_2, \dots, s_{|S|}\}$ 表示会话集,其中 $s = \{(v_i, r_j) | v_i \in V, r_j \in R, 1 < i \leq n\}$ 为一个按时间戳先后排序的由微观行为 (v_i, r_j) 组成的匿名会话序列。给定任意会话 s ,会话推荐的目标是估计用户在目标操作 $r_{|R|}$ 场景与 V 中所有物品交互的概率 \hat{y} , \hat{y} 中的每一个元素表示相应物品的推荐分数,然后将分数

高的前几个物品推荐给用户。AMAN 模型的总体框架如图 2 所示。



注:红色箭头表示会话中的最后一个物品

图 2 AMAN 模型的框架图(电子版为彩图)

Fig. 2 Framework of AMAN model

3.2 异构有向图构建

将会话序列 $s = \{(v_i, r_j) | v_i \in V, r_j \in R\}$ 建模为异构有向图 $G_s = (V_s, E_s)$,其中 V_s 为节点的集合,每一个节点表示一个物品 v_i ; E_s 为边的集合,每一条有向边 (v_i, r_k, v_j) 代表一个微观操作 r_k ,表示用户在 v_i 之后操作 v_j 。

3.3 物品表征

会话序列中的物品不仅受具有相同微观操作的物品的影响,而且受具有不同微观操作的物品的影响。现有方法通常忽略了具有不同微观操作的物品间的关联性。因此,本文通过物品级注意力模块自适应捕获具有相同微观操作的物品间的关联性,通过操作级注意力模块自适应捕获具有不同微观操作的物品间的关联性,以增强物品表征。

3.3.1 物品级注意力模块

具有相同微观操作的物品通常具有共同的特征或特定的关系。例如,在“购买”行为下出现的物品通常具有互补关系,而在“点击”行为下出现的物品通常具有替换关系。因此,将具有相同微观操作的邻居物品的信息聚合有助于获得更好的物品表征。此外,具有相同微观操作的行为序列中的不同物品具有不同的重要性。受文献^[23]的启发,本文提出了一种有向图注意力网络(DGAT),用于聚合具有相同微观操作的邻居物品的信息,并自适应地学习每个邻居物品的权重。

首先,通过可学习嵌入矩阵 $W \in \mathbb{R}^{d \times |V|}$ 将每个物品的 one-hot 向量转化到维度统一为 d 的低维特征空间 $x_i \in \mathbb{R}^d$ 。

$$x_i = W \cdot \text{one-hot}(v_i) \quad (1)$$

然后,计算 DGAT 的自注意力权重 $e_{ij,r}$,它决定了基于特定微观操作 r 的节点 j 对节点 i 的重要性。

$$e_{ij,r} = \text{att}_{\text{item}}(x_i, x_j; r) \quad (2)$$

其中, att_{item} 表示执行物品级注意力机制的神经网络; $e_{ij,r}$ 是非对称的,因为基于特定操作 r 的节点 j 对节点 i 的重要性可能与节点 i 对节点 j 的重要性不同。实验中,通过参数为 $b_r \in \mathbb{R}^{2d}$ 的 MLP 层和 sigmoid 函数实现 att_{item} 。

$$\text{att}_{\text{item}}(x_i, x_j; r) = \sigma(b_r^\top [x_i; x_j]) \quad (3)$$

其中, σ 是 sigmoid 函数, \top 表示转置, $[\cdot]$ 表示按列拼接。

为了直接比较相同操作中不同节点的重要性,使用 softmax 函数将权重归一化。

$$\alpha_{ij,r} = \text{softmax}(\mathbf{e}_{ij,r}) = \frac{\exp(\mathbf{e}_{ij,r})}{\sum_{k \in N_{i,r}, r \in \{r^+, r^-, r^*\}} \exp(\mathbf{e}_{ik,r})} \quad (4)$$

其中, $k \in N_{i,r}$ 表示节点 i (包含自身的) 基于操作 r 的邻居节点集, r^+ 表示节点 k 在节点 i 之后发生, 与之相反, r^- 表示节点 k 在节点 i 之前发生, r^* 表示节点 i 自身。由于会话图较小, 实验中考虑节点 i 基于微观操作 r 的所有邻居节点。区分边的方向的原因是用户的兴趣可能随着时间的推移而发生改变, 一个物品的前导和后继反映了用户的不同兴趣。

扩展的基于特定操作 r 的节点 j 对节点 i 的权重计算方法如式(5)所示:

$$\alpha_{ij,r} = \frac{\exp(\sigma(\mathbf{b}_r^\top [\mathbf{x}_i \parallel \mathbf{x}_j]))}{\sum_{k \in N_{i,r}, r \in \{r^+, r^-, r^*\}} \exp(\sigma(\mathbf{b}_r^\top [\mathbf{x}_i \parallel \mathbf{x}_k]))} \quad (5)$$

最后, 将包含自身在内的邻居节点表征与相应权重聚合, 得到节点 i 基于微观操作 r 的表征 $\mathbf{h}_{i,r}$ 。

$$\mathbf{h}_{i,r} = \sigma\left(\sum_{j \in N_{i,r}, r \in \{r^+, r^-, r^*\}} \alpha_{ij,r} \mathbf{x}_j\right) \quad (6)$$

因为 $\alpha_{ij,r}$ 基于单一操作生成, 所以具有语义单一性, 只能承载某种语义信息。

多头注意力可以稳定自注意力的训练过程, 提升推荐性能, 因此将物品级注意力学习过程重复 K 次并取平均值, 得到扩展的基于微观操作 r 的节点 i 的表征 $\mathbf{h}_{i,r}$ 。

$$\mathbf{h}_{i,r} = \sigma\left(\frac{1}{K} \sum_{k=1}^K \sum_{j \in N_{i,r}, r \in \{r^+, r^-, r^*\}} \alpha_{ij,r}^k \mathbf{x}_j^k\right) \quad (7)$$

3.3.2 操作级注意力模块

通常异构图中的每个物品节点可能与多个微观操作相关, 聚合不同微观操作的物品表征有助于获得更全面的物品信息。本文提出了一种操作级异构图注意力网络(OHGAT), 该网络自适应学习节点不同微观操作的重要性, 并将其集成到节点表征任务中。

首先, 计算自注意力权重 $\mathbf{e}_{i,r}$, 它决定了操作 r 对节点 i 的重要性。

$$\mathbf{e}_{i,r} = \text{att}_{\text{behavior}}(\mathbf{h}_{i,r}) \quad (8)$$

其中, $\text{att}_{\text{behavior}}$ 表示执行操作级注意力机制的神经网络。实验中, $\text{att}_{\text{behavior}}$ 的计算方法如式(9)所示:

$$\text{att}_{\text{behavior}}(\mathbf{h}_{i,r}) = \frac{1}{|V_s|} \sum_{i \in V_s} \mathbf{q}^\top \tanh(\mathbf{M}\mathbf{h}_{i,r} + \mathbf{p}) \quad (9)$$

其中, $\mathbf{M} \in \mathbb{R}^{d \times d}$ 是权重矩阵, $\mathbf{p} \in \mathbb{R}^d$ 是偏置向量, $\mathbf{q} \in \mathbb{R}^d$ 是操作级注意力向量, V_s 是会话 s 的节点集, $|V_s|$ 是会话 s 的长度。

然后, 使用 softmax 函数将权重 $\mathbf{e}_{i,r}$ 归一化。

$$\beta_{i,r} = \text{softmax}(\mathbf{e}_{i,r}) = \frac{\exp(\mathbf{e}_{i,r})}{\sum_{r \in R_i} \exp(\mathbf{e}_{i,r})} \quad (10)$$

其中, R_i 表示节点 i 的邻居操作集。

扩展的操作权重计算方法如式(11)所示:

$$\beta_{i,r} = \frac{\exp\left(\frac{1}{|V_s|} \sum_{i \in V_s} \mathbf{q}^\top \tanh(\mathbf{M}\mathbf{h}_{i,r} + \mathbf{p})\right)}{\sum_{r \in R_i} \exp\left(\frac{1}{|V_s|} \sum_{i \in V_s} \mathbf{q}^\top \tanh(\mathbf{M}\mathbf{h}_{i,r} + \mathbf{p})\right)} \quad (11)$$

最后, 将操作向量与相应的权重聚合, 获得节点 i 融合多种微观操作的表征 \mathbf{h}_i 。

$$\mathbf{h}_i = \sum_{r \in R_i} \beta_{i,r} \mathbf{h}_{i,r} \quad (12)$$

3.4 微观行为序列表征

获得物品表征之后, 需要进一步学习微观行为序列表征。会话序列中的每种微观行为序列都包含丰富的语义信息, 不同的微观行为序列相互补充、相互影响, 具有一定的依赖性。现有的研究没有充分利用各种微观行为序列间的依赖性。受文献[24]的启发, 本文提出微观行为协同注意力网络(MB-CAT), 从物品级自适应学习不同微观行为序列间的依赖性。

3.4.1 目标行为和辅助行为间的关联矩阵

根据微观操作, 从会话序列中抽取目标操作对应的物品序列 $P = [v_1, v_2, \dots, v_{|P|}]$ 和辅助操作对应的物品序列集 $Q = \{Q_1, Q_2, \dots, Q_{|R|-1}\}$, 其中 $Q_i = [v_1, v_2, \dots, v_*]$ 是辅助操作 r_i 对应的物品序列, $*$ 是每种辅助行为序列的平均长度。根据 OHGAT 获得的物品表征, 得到目标行为矩阵 $\mathbf{P} \in \mathbb{R}^{d \times m}$ 和辅助行为矩阵 $\mathbf{Q} \in \mathbb{R}^{d \times n}$, 其中 m 为目标行为序列的平均长度, n 为不同辅助行为序列的平均长度的和。

定义目标行为序列与辅助行为序列之间的关联矩阵 $\mathbf{C} \in \mathbb{R}^{m \times n}$, 具体如下:

$$\mathbf{C} = \mathbf{P}^\top \times \mathbf{W}_c \times \mathbf{Q} \quad (13)$$

其中, $\mathbf{W}_c \in \mathbb{R}^{d \times d}$ 为可学习参数矩阵。关联矩阵 \mathbf{C} 协同关注目标行为和辅助行为的语义, 其中的每个元素表示两个对应向量间的语义相关性。

3.4.2 目标行为序列表征

将最相关的辅助行为信息融合到目标行为序列表征中, 计算方法如式(14)、式(15)所示:

$$\mathbf{H}_p = \tanh(\mathbf{W}_p \mathbf{P} + (\mathbf{W}_q \mathbf{Q} + \mathbf{W}_1 \mathbf{h}_{|s|}) \mathbf{C}^\top) \quad (14)$$

$$\alpha_p = \text{softmax}(\mathbf{W}_2^\top \mathbf{H}_p) \quad (15)$$

其中, $\mathbf{W}_p, \mathbf{W}_q, \mathbf{W}_1 \in \mathbb{R}^{d \times d}$ 和 $\mathbf{W}_2 \in \mathbb{R}^d$ 为可学习参数矩阵, $\mathbf{h}_{|s|}$ 是会话中最后一个物品的表征, 如图 2 中红色箭头所示, $|s|$ 为会话长度。

根据注意力权重, 可以计算出融合辅助行为信息的目标行为序列表征。

$$\mathbf{S}_p = \sum_{i=1}^{|P|} \alpha_p^i \mathbf{h}_p^i \quad (16)$$

其中, \mathbf{h}_p^i 表示目标行为序列 P 中第 i 个物品的表征, $|P|$ 表示目标行为序列的长度。

融合 $\mathbf{h}_{|s|}$ 的目标行为序列表征为:

$$\mathbf{S}_{\text{target}} = [\mathbf{S}_p \parallel \mathbf{h}_{|s|}] \quad (17)$$

3.4.3 辅助行为序列表征

将目标行为信息融合到辅助行为序列表征中, 辅助行为序列的最终表征 $\mathbf{S}_{\text{auxiliary}}$ 的计算方法如下:

$$\mathbf{H}_q = \tanh(\mathbf{W}_q \mathbf{Q} + \mathbf{W}_1 \mathbf{h}_{|s|} + (\mathbf{W}_p \mathbf{P}) \mathbf{C}) \quad (18)$$

$$\alpha_q = \text{softmax}(\mathbf{W}_3^\top \mathbf{H}_q) \quad (19)$$

$$\mathbf{S}_q = \sum_{i=1}^{|Q|} \sum_{j=1}^{|Q_i|} \alpha_q^i \mathbf{h}_{q_i}^j \quad (20)$$

$$\mathbf{S}_{\text{auxiliary}} = [\mathbf{S}_q \parallel \mathbf{h}_{|s|}] \quad (21)$$

其中, $\mathbf{W}_3 \in \mathbb{R}^d$ 为可学习参数矩阵, $\mathbf{h}_{q_i}^j$ 表示第 i 个辅助行为序列 Q_i 中第 j 个物品的表征, $|Q|$ 表示辅助行为序列集合的大小, $|Q_i|$ 表示第 i 个辅助行为序列的长度。

3.5 预测与模型训练

根据目标行为序列表征、辅助行为序列表征和物品表征计算物品集 V 中每个物品的推荐分数。

$$\mathbf{H}=[h_1;h_2;\cdots;h_{|V|}] \quad (22)$$

$$\hat{\mathbf{z}}_P=\mathbf{H}^T\mathbf{B}_P\mathbf{S}_{\text{target}} \quad (23)$$

$$\hat{\mathbf{z}}_Q=\mathbf{H}^T\mathbf{B}_Q\mathbf{S}_{\text{auxiliary}} \quad (24)$$

$$\hat{\mathbf{z}}=\sigma(\mathbf{B}^T[\hat{\mathbf{z}}_P;\hat{\mathbf{z}}_Q]) \quad (25)$$

其中, $[\cdot]$ 表示按列拼接; $\mathbf{B}_P,\mathbf{B}_Q\in\mathbb{R}^{d\times 2d}$ 和 $\mathbf{B}\in\mathbb{R}^2$ 是可学习参数; $\hat{\mathbf{z}}_P$ 表示基于目标行为序列表征的推荐分数; $\hat{\mathbf{z}}_Q$ 表示基于辅助行为序列表征的推荐分数。

在 $\hat{\mathbf{z}}$ 上应用 softmax 函数,将其转换为概率 $\hat{\mathbf{y}}$,选择 $\hat{\mathbf{y}}$ 中取值最高的前 K 个物品进行推荐。

$$\hat{\mathbf{y}}=\text{softmax}(\hat{\mathbf{z}}) \quad (26)$$

采用神经网络反向传播算法,通过最小化预测值与真实值之间的交叉熵损失函数优化推荐模型。损失函数的定义如下:

$$L(\hat{\mathbf{y}})=-\sum_{i=1}^{|V|}y_i\log(\hat{y}_i)+(1-y_i)\log(1-\hat{y}_i) \quad (27)$$

其中, y_i 为真实物品的 one-hot 向量。

4 AMAN 复杂度分析

(1) 时间复杂度

AMAN 模型的时间成本主要来自物品表征模块、微观行为序列表征模块和预测模块。物品表征模块中物品级注意力模块的时间复杂度为 $O(|V_s|\times d\times|V|+|E_s|\times d)$,操作级注意力模块的时间复杂度为 $O(|R|\times d^2)$,物品级注意力模块和操作级注意力模块可以分别通过跨节点和操作并行化。微观行为序列表征模块的时间复杂度为 $O(d\times m\times n^2)$ ($m<n$)。预测模块的时间复杂度为 $O(|V|\times d^2)$ 。其中, $|V_s|$ 和 $|E_s|$ 分别是异构有向图的节点集大小和边集大小, $|V|$ 表示物品集大小, $|R|$ 表示微观操作集大小, d 表示物品维度, m 为目标行为序列的平均长度, n 为不同辅助行为序列的平均长度的和。

(2) 参数空间复杂度

AMAN 模型的可学习参数主要来自物品表征模块、微观行为序列表征模块和预测模块。物品表征模块的参数空间复杂度为 $O(|V|\times d)$,微观行为序列表征模块的参数空间复杂度为 $O(d^2)$,预测模块的参数空间复杂度为 $O(d^2)$ 。其中, $|V|$ 表示物品集, d 表示物品维度。

5 实验结果与分析

5.1 数据集

本文在 Yoochoose, Taobao14 和 Taobao15 这 3 个公开数据集上评估 AMAN 模型的推荐性能。首先,对数据集做如下处理。1) 在 Yoochoose 中,指定 buy 是目标操作,click 是辅助操作;在 Taobao14 中,指定 payment 是目标操作,辅助操作包括 click, collect 和 add-to-cart;在 Taobao15 中,指定 purchase 是目标操作,click, add-to-cart 和 favourite 是辅助操作。2) 过滤数据集中长度为 1 的信息量不足的会话(参考文献

[9]),当某种微观行为序列的长度大于阈值 L 时,只保留最新的 L 个物品,阈值的取值为数据集中对应微观行为序列的平均长度。3) 应用数据增强技术^[14]构造训练样本。将长度为 n 的会话序列分割成 $n-1$ 个长度为 2 到 n 的部分序列扩充数据集。例如,目标行为序列 $[v_1, v_2, \dots, v_{|P|}]$ 的输入和相应标签为 $(\{v_1\}, v_2), (\{v_1, v_2\}, v_3), \dots, (\{v_1, v_2, \dots, v_{|P|-1}\}, v_{|P|})$ 。辅助行为序列的数据增强方法与目标行为序列类似,但是为了避免辅助输入已经看到标签(参考文献[9]),仅保留标签之前的辅助操作下的物品作为辅助行为序列。4) 按时间顺序提取前 80% 的数据集作为训练集,将后 10% 作为验证集进行参数调优,剩下的 10% 作为测试集。表 1 所列为数据集的详细信息。

表 1 数据集统计

Table 1 Statistics of datasets

| 数据集 | Yoochoose | Taobao14 | Taobao15 |
|-----|-------------|-------------|-------------|
| 会话数 | 9 249 729 | 987 994 | 424 170 |
| 物品数 | 52 739 | 2 876 947 | 1 090 390 |
| 时间 | 2014/04/01— | 2014/11/18— | 2015/05/11— |
| 跨度 | 2014/09/30 | 2014/12/18 | 2015/11/11 |

5.2 对比模型

为了评估 AMAN 模型的性能,选择包含经典模型和最新研究成果的 10 个模型进行比较。

(1) 单行为模型,包括传统推荐模型(POP, S-POP, IKNN^[11], FPMC^[13])和基于深度学习的模型(GRU4REC^[4], NARM^[5], STAMP^[6], SR-GNN^{[1][7]})。

(2) 微观行为模型,包括 MGNN-SPred^{[2][9]}和 MKM-SR^{[3][10]}。

对于 POP, S-POP, IKNN, FPMC, GRU4REC, NARM 和 STAMP,使用 Ludewig 等^[25]提供的源代码,相关参数使用原始论文中给出的默认值。MGNN-SPred 使用 buy/payment/purchase 为目标操作,click 为辅助操作。MKM-SR 移除学习知识嵌入的辅助任务。对于单行为模型,仅使用目标操作对应的行为序列。

5.3 评价指标

本文使用 R@K 和 MRR@K 作为评价指标。R@K (Recall calculated over top-K items) 用于衡量预测精度,表示在推荐列表 top-K 个物品中正确推荐的物品的比例。MRR@K (Mean Reciprocal Rank calculated over top-K items) 表示在推荐列表 top-K 个物品中正确推荐的物品的排名倒数的平均值。当排名大于 K 时,排名倒数设为 0。

为了验证模型的泛化能力,同时考虑到不同用户对推荐数量的不同需求,实验中考虑 $K\in\{5, 10, 20, 50, 100\}$ 。

5.4 参数设置

参考文献[5-6],从训练集中随机选取 1/10 作为验证集进行超参数调优。所有参数用均值为 0、标准差为 0.1 的高斯分布进行初始化。本文使用 Adam 优化器,批大小设置为 128, dropout 为 0.2, 初始学习率为 0.001, 每 3 个 epoch 后

¹⁾ <https://github.com/CRIPAC-DIG/SR-GNN>

²⁾ <https://github.com/Autumn945/MGNN-SPred>

³⁾ <https://github.com/ciecus/MKM-SR>

衰减 0.1, L2 正则化系数为 10^{-5} , 多头自注意力头数为 4。

5.5 性能比较

Yoochoose 数据集的向量维度为 64, 两个 Taobao 数据集的向量维度为 128。

为了验证 AMAN 模型的整体性能, 将其与基准模型进行比较, 实验结果如表 2—表 4 所列。

表 2 不同模型在 Yoochoose 上的实验结果

Table 2 Experimental results of different models on Yoochoose

| 方法 | R@ | | | | | MRR@ | | | | |
|-------------|---------------|----------------|----------------|----------------|----------------|---------------|---------------|---------------|---------------|---------------|
| | 5 | 10 | 20 | 50 | 100 | 5 | 10 | 20 | 50 | 100 |
| POP | 0.0000 | 0.0000 | 0.0273 | 0.0545 | 0.0955 | 0.0000 | 0.0000 | 0.0020 | 0.0027 | 0.0032 |
| S-POP | 0.1818 | 0.1818 | 0.1864 | 0.2091 | 0.2364 | 0.1252 | 0.1252 | 0.1254 | 0.1259 | 0.1263 |
| IKNN | 0.3273 | 0.4182 | 0.4773 | 0.5545 | 0.5818 | 0.2147 | 0.2275 | 0.2317 | 0.2343 | 0.2346 |
| FPMC | 0.1500 | 0.1591 | 0.1591 | 0.1818 | 0.1818 | 0.1062 | 0.1075 | 0.1075 | 0.1083 | 0.1083 |
| GRU4REC | 0.3864 | 0.4773 | 0.5818 | 0.6591 | 0.7227 | 0.2311 | 0.2436 | 0.2510 | 0.2537 | 0.2546 |
| NARM | 0.3682 | 0.4955 | 0.5682 | 0.6773 | 0.7136 | 0.1966 | 0.2139 | 0.2195 | 0.2227 | 0.2233 |
| STAMP | 0.3318 | 0.4773 | 0.5991 | 0.6227 | 0.6909 | 0.1846 | 0.2041 | 0.2097 | 0.2119 | 0.2128 |
| SR-GNN | 4.3060 | 7.0980 | 11.0554 | 16.9118 | 21.2605 | 2.5229 | 2.6542 | 2.7010 | 2.7862 | 2.8224 |
| MGNN-SPred | 5.2600 | 9.1100 | 14.1200 | 22.3700 | 28.6300 | 2.7500 | 3.0100 | 3.4500 | 3.5700 | 3.6600 |
| MKM-SR | <u>5.4441</u> | <u>9.6912</u> | <u>15.1818</u> | <u>24.4057</u> | <u>31.3556</u> | <u>2.7866</u> | <u>3.0711</u> | <u>3.5417</u> | <u>3.8182</u> | <u>3.9401</u> |
| AMAN (ours) | 5.7163 | 10.4259 | 16.4966 | 26.7316 | 35.1841 | 2.8850 | 3.2345 | 3.7814 | 4.1236 | 4.2750 |
| Improve | 5.00 | 7.58 | 8.66 | 9.53 | 12.21 | 3.53 | 5.32 | 6.77 | 8.00 | 8.50 |

注: 显示的结果是每个模型 5 次运行结果的平均值, 每列中的最佳结果和次优结果分别用黑体和下划线标出, 最后一行为 AMAN 模型相比最佳基准模型提高的百分点

表 3 不同模型在 Taobao14 上的实验结果

Table 3 Experimental results of different models on Taobao14

| 方法 | R@ | | | | | MRR@ | | | | |
|-------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|
| | 5 | 10 | 20 | 50 | 100 | 5 | 10 | 20 | 50 | 100 |
| POP | 0.0305 | 0.0355 | 0.0355 | 0.1320 | 0.1827 | 0.0305 | 0.0305 | 0.0308 | 0.0341 | 0.0349 |
| S-POP | 0.8071 | 0.8071 | 0.8122 | 0.8274 | 0.8426 | 0.7766 | 0.7766 | 0.7770 | 0.7775 | 0.7777 |
| IKNN | 0.1218 | 0.1320 | 0.1371 | 0.1726 | 0.1929 | 0.0745 | 0.0761 | 0.0764 | 0.0774 | 0.0777 |
| FPMC | 0.7919 | 0.7970 | 0.8020 | 0.8223 | 0.8325 | 0.7716 | 0.7723 | 0.7726 | 0.7731 | 0.7732 |
| GRU4REC | 0.8274 | 0.8680 | 0.8934 | 0.9086 | 0.9137 | 0.7086 | 0.7144 | 0.7160 | 0.7164 | 0.7165 |
| NARM | 0.8426 | 0.9036 | 0.9391 | 0.9695 | 0.9797 | 0.7404 | 0.7478 | 0.7504 | 0.7515 | 0.7517 |
| STAMP | 0.6244 | 0.7716 | 0.8376 | 0.9441 | 0.9644 | 0.4157 | 0.4360 | 0.4407 | 0.4442 | 0.4445 |
| SR-GNN | 13.4816 | 17.1684 | 23.4775 | 28.1155 | 35.2692 | 11.8464 | 11.9648 | 12.0280 | 12.2804 | 12.7695 |
| MGNN-SPred | 16.6064 | 22.2181 | 30.3500 | 37.4293 | 47.7559 | 13.0046 | 13.6623 | 14.4712 | 15.2234 | 15.6870 |
| MKM-SR | <u>17.2391</u> | <u>23.6601</u> | <u>32.6718</u> | <u>40.8953</u> | <u>52.3548</u> | <u>13.1958</u> | <u>13.9601</u> | <u>15.9028</u> | <u>15.9469</u> | <u>16.1501</u> |
| AMAN (ours) | 18.1528 | 25.4819 | 35.6123 | 44.9030 | 58.8468 | 13.6471 | 14.7502 | 17.0144 | 17.0993 | 17.3835 |
| Improve | 5.30 | 7.70 | 9.00 | 9.80 | 12.40 | 3.42 | 5.66 | 6.99 | 7.23 | 7.64 |

注: 显示的结果是每个模型 5 次运行结果的平均值, 每列中的最佳结果和次优结果分别用黑体和下划线标出, 最后一行为 AMAN 模型相比最佳基准模型提高的百分点

表 4 不同模型在 Taobao15 上的实验结果

Table 4 Experimental results of different models on Taobao15

| 方法 | R@ | | | | | MRR@ | | | | |
|-------------|---------------|---------------|---------------|----------------|----------------|---------------|---------------|---------------|---------------|---------------|
| | 5 | 10 | 20 | 50 | 100 | 5 | 10 | 20 | 50 | 100 |
| POP | 0.0038 | 0.0038 | 0.0038 | 0.0038 | 0.0113 | 0.0008 | 0.0008 | 0.0008 | 0.0008 | 0.0009 |
| S-POP | 0.2189 | 0.2264 | 0.2264 | 0.2264 | 0.2264 | 0.1877 | 0.1885 | 0.1885 | 0.1885 | 0.1885 |
| IKNN | 0.0868 | 0.0943 | 0.1094 | 0.1094 | 0.1132 | 0.0563 | 0.0573 | 0.0585 | 0.0585 | 0.0586 |
| FPMC | 0.1962 | 0.2075 | 0.2113 | 0.2189 | 0.2226 | 0.1657 | 0.1674 | 0.1676 | 0.1679 | 0.1679 |
| GRU4REC | 0.1925 | 0.2264 | 0.2491 | 0.2906 | 0.3019 | 0.1472 | 0.1516 | 0.1532 | 0.1544 | 0.1546 |
| NARM | 0.2302 | 0.2755 | 0.2981 | 0.3245 | 0.3396 | 0.1804 | 0.1861 | 0.1875 | 0.1884 | 0.1886 |
| STAMP | 0.1811 | 0.2151 | 0.2491 | 0.2717 | 0.2830 | 0.1380 | 0.1429 | 0.1455 | 0.1463 | 0.1464 |
| SR-GNN | 2.6473 | 4.4080 | 6.2601 | 8.4370 | 10.5276 | 1.9844 | 2.0471 | 2.0625 | 2.1347 | 2.2369 |
| MGNN-SPred | 3.2507 | 5.6944 | 8.0655 | 11.2141 | 14.2344 | 2.1693 | 2.3290 | 2.6482 | 2.7127 | 2.7719 |
| MKM-SR | <u>3.3742</u> | <u>6.0588</u> | <u>8.6785</u> | <u>12.2458</u> | <u>15.6009</u> | <u>2.1997</u> | <u>2.3779</u> | <u>2.7202</u> | <u>2.9020</u> | <u>2.9851</u> |
| AMAN (ours) | 3.5503 | 6.5211 | 9.4335 | 13.4214 | 17.5198 | 2.2787 | 2.5049 | 2.9052 | 3.1385 | 3.2406 |
| Improve | 5.22 | 7.63 | 8.70 | 9.60 | 12.30 | 3.59 | 5.34 | 6.80 | 8.15 | 8.56 |

注: 显示的结果是每个模型 5 次运行结果的平均值, 每列中的最佳结果和次优结果分别用黑体和下划线标出, 最后一行为 AMAN 模型相比最佳基准模型提高的百分点

由表 2—表 4 可得出如下结论:

(1)所有方法在 Taobao14, Yoochoose 和 Taobao15 上的性能依次降低,原因是 Taobao15 包含用户双十一的行为,因为促销活动,用户兴趣严重漂移。Taobao14 相比 Yoochoose 时间跨度更小,用户操作类型更多,实验效果最好。随着推荐数量 K 的减少,所有方法在 R 和 MRR 指标上均呈下降趋势,说明推荐指标严苛时推荐效果有所下降。

(2)GRU4REC, NARM, STAMP 和 SR-GNN 这 4 个基于深度学习的模型取得了比非深度学习更优的效果,说明深度学习成为了会话推荐的主流方法。上述 4 个模型基于购买行为建立,实验性能指标低于原始论文。STAMP 考虑最后一个物品中蕴含的当前兴趣,在 3 个数据集中效果最差,可能的原因是用户对最近已经购买的物品不太感兴趣。SR-GNN 使用图神经网络建模物品之间的复杂依赖关系,推荐效果优于基于 RNN 的方法。

(3)微观行为模型优于单行为模型。MGNN-SPred 和 MKM-SR 的比较结果表明,一方面考虑更多的微观行为能够提升会话推荐性能,另一方面建立由微观行为组成的会话序列中的物品、操作、微观行为之间的关系非常重要。

(4)AMAN 模型优于上述所有基线模型。与对比实验中性能最佳的 MKM-SR 模型相比,AMAN 在 Yoochoose, Taobao14 和 Taobao15 这 3 个数据集上, $R@20$ 分别提高了 8.66%, 9.00% 和 8.70%, $MRR@20$ 分别提高了 6.77%, 6.99% 和 6.80%,证明了用户微观行为在会话推荐中的有效性。AMAN 在 Yoochoose 上的性能提升优于两个 Taobao 数据集,可能的原因是 Yoochoose 数据集中目标行为序列的平均长度较短,不能很好地推断用户意图,使用多种微观行为能够提升推荐性能。

5.6 消融实验

通过消融实验验证 AMAN 模型中各个组件的有效性。本次实验中,“AMAN”表示模型的完整版本;“w/o DGAT”表示移除 DGAT 组件,并简单地用式(1)获得的低维表征初始化 OHGAT 的输入;“w/o OHGAT”表示移除 OHGAT 模块;“w/o MBCAT”表示移除 MBCAT 模块,对 OHGAT 获得的物品表征求和,从而获得目标行为序列表征和辅助行为序列表征。实验结果如表 5 所列。

表 5 消融实验结果

Table 5 Ablation results

| 方法 | Yoochoose | | Taobao14 | | Taobao15 | |
|-----------|-----------|--------|----------|---------|----------|--------|
| | R@20 | MRR@20 | R@20 | MRR@20 | R@20 | MRR@20 |
| w/o DGAT | 15.6718 | 3.6680 | 34.1878 | 16.3849 | 9.0562 | 2.8122 |
| w/o OHGAT | 16.1238 | 3.6869 | 34.5439 | 16.6401 | 9.1505 | 2.8297 |
| w/o MBCAT | 16.2656 | 3.7360 | 34.9001 | 16.8443 | 9.2731 | 2.8761 |
| AMAN | 16.4966 | 3.7814 | 35.6123 | 17.0144 | 9.4335 | 2.9052 |

由表 5 可得出以下结论:

(1)有向图注意力网络 DGAT 能够捕获具有相同微观操作的物品间的关联性,在会话推荐任务中贡献显著。移除该组件,在 Yoochoose, Taobao14 和 Taobao15 这 3 个数据集上, $R@20$ 分别降低了 5%, 4%, 4%, $MRR@20$ 分别降低了 3%, 3.7%, 3.2%。

(2)操作级异构图注意力网络 OHGAT 能够捕获具有不同微观操作的物品间的关联性,提升会话推荐性能。移除该组件,在 Yoochoose, Taobao14 和 Taobao15 这 3 个数据集上, $R@20$ 分别降低了 2.26%, 3%, 3%, $MRR@20$ 分别降低了 2.5%, 2.2%, 2.6%。

(3)微观行为协同注意力网络 MBCAT 能够捕获不同微观行为序列间的依赖性,为会话推荐提供了积极贡献。移除该组件,在 Yoochoose, Taobao14 和 Taobao15 这 3 个数据集上, $R@20$ 分别降低了 1.4%, 2%, 1.7%, $MRR@20$ 分别降低了 1.2%, 1%, 1%。

(4)AMAN 不仅能够学习物品间的关联性,而且能够学习行为间的依赖性,实验效果最好,论证了三者结合使用的必要性,三者缺一不可。

5.7 不同微观行为序列融合方式分析

为了探究微观行为融合方式对 AMAN 模型推荐性能的影响,采用“求和”“拼接”“门控”和“协同注意力”4 种融合方式进行实验验证。“求和”指对物品表征求和,从而获得会话表征;“拼接”和“门控”根据操作类型对物品表征求和,从而获得目标行为序列表征和辅助行为序列表征,对目标行为序列表征和辅助行为序列表征分别进行拼接和门控融合,从而得到会话表征,对上述会话表征与物品集中的每一个物品求相似度,完成推荐。表 6 列出了 MGNN-SPred 模型和 AMAN 模型采用不同微观行为融合方式的实验结果,本文以 @20 为例进行说明。

表 6 微观行为序列融合方式的实验结果

Table 6 Experimental results of fusion method of micro behavior sequence

| 数据集 | 模型 | 指标 | 求和 | 拼接 | 门控 | 协同注意力 |
|-----------|------------|--------|---------|---------|---------|---------|
| Yoochoose | MGNN-SPred | R@20 | 12.0975 | 13.1973 | 14.1200 | 14.2121 |
| | | MRR@20 | 2.7730 | 3.0251 | 3.4500 | 3.4752 |
| | AMAN | R@20 | 16.2622 | 16.2713 | 16.2971 | 16.4966 |
| | | MRR@20 | 3.7340 | 3.7395 | 3.7420 | 3.7814 |
| Taobao14 | MGNN-SPred | R@20 | 26.1157 | 28.4898 | 30.3500 | 30.5762 |
| | | MRR@20 | 12.4772 | 13.6115 | 14.4712 | 14.5310 |
| | AMAN | R@20 | 34.9000 | 35.0553 | 35.3640 | 35.6123 |
| | | MRR@20 | 16.8442 | 16.9210 | 16.9458 | 17.0144 |
| Taobao15 | MGNN-SPred | R@20 | 6.9179 | 7.5468 | 8.0655 | 8.1759 |
| | | MRR@20 | 2.1305 | 2.3242 | 2.6482 | 2.6513 |
| | AMAN | R@20 | 9.2730 | 9.2755 | 9.3100 | 9.4335 |
| | | MRR@20 | 2.8761 | 2.8830 | 2.8869 | 2.9052 |

由表 6 可知,本文微观行为协同注意力融合方式从物品级

融合目标行为信息和辅助行为信息,实验效果最好。“门控”

机制能够自动学习目标行为序列和辅助行为序列的重要性,但是不能区分不同辅助行为序列对目标行为序列的重要性,实验效果次之。“拼接”操作不能区分目标行为序列和辅助行为序列的重要性,实验效果差于“门控”机制。“求和”不区分目标行为和辅助行为,实验效果最差。MGNN-SPred 模型使用本文提出的协同注意力机制取得了比原始论文中门控机制更好的效果,验证了充分挖掘并利用不同微观行为序列之间的依赖性能够提升推荐性能。

结束语 本文将会话序列建模为基于微观行为序列的异构有向图,提出了 AMAN 会话推荐模型。通过有向图注意力网络(DGAT)和操作级异构图注意力网络(OHGAT)分别从物品级和操作级学习物品表征,自适应捕获具有相同和不同微观操作的物品间的关联性。通过微观行为协同注意力网络(MBCAT)学习微观行为序列表征,自适应捕获不同微观行为序列间的依赖性。在 Yoochoose, Taobao14 和 Taobao15 这 3 个数据集上的实验结果表明,本文方法优于最先进的基线模型。事实上,可以将任一微观操作作为目标操作,以提升目标操作应用场景的推荐性能。在后续的研究中,计划用更多的辅助信息(如内容信息)生成更具信息量的物品表征,以扩展 AMAN 模型,同时探索用户行为序列中蕴含的多种兴趣(如一般兴趣、原始兴趣和当前兴趣)并进行融合,以提升 SR 的推荐性能。


参 考 文 献

- [1] WANG S, CAO L, WANG Y, et al. A Survey on Session-based Recommender Systems[EB/OL]. (2019-02-13) [2020-09-13]. <https://arxiv.org/abs/1902.04864>.
- [2] CAO Y, ZHANG W, SONG B, et al. Position-Aware Context Attention for Session-based Recommendation[J]. *Neurocomputing*, 2020, 376: 65-72.
- [3] GUO Y, ZHANG D, LING Y, et al. A Joint Neural Network for Session-Aware Recommendation [J]. *IEEE Access*, 2020, 8: 74205-74215.
- [4] HIDASI B, KARATZOGLOU A, BALTRUNAS L, et al. Session-based Recommendations with Recurrent Neural Networks [EB/OL]. (2016-03-29) [2020-09-29]. <https://arxiv.org/abs/1511.06939>.
- [5] LI J, REN P, CHEN Z, et al. Neural Attentive Session-based Recommendation[C]//Proceedings of the 26th ACM on Conference on Information and Knowledge Management. ACM, 2017: 1419-1428.
- [6] LIU Q, ZENG Y, MOKHOSI R, et al. STAMP: Short-Term Attention/Memory Priority Model for Session-based Recommendation[C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2018: 1831-1839.
- [7] WU S, TANG Y, ZHU Y, et al. Session-based Recommendation with Graph Neural Networks[C]//Proceedings of the 33rd AAAI Conference on Artificial Intelligence. AAAI, 2019: 346-353.
- [8] XU C, ZHAO P, LIU Y, et al. Graph Contextualized Self-attention Network for Session-based Recommendation[C]//Proceedings of the 27th International Joint Conference on Artificial Intelligence. AAAI, 2018: 3940-3946.
- [9] WANG W, ZHANG W, LIU S, et al. Beyond Clicks: Modeling Multi-Relational Item Graph for Session-Based Target Behavior Prediction[C]//Proceedings of the 2020 World Wide Web Conference. ACM, 2020: 3056-3062.
- [10] MENG W, YANG D, XIAO Y. Incorporating User Micro-behaviors and Item Knowledge into Multi-task Learning for Session-based Recommendation [C] // Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2020: 1091-1100.
- [11] SARWAR B, KARYPIS G, KONSTAN J, et al. Item-based Collaborative Filtering Recommendation Algorithms [C] // Proceedings of the 10th International Conference on World Wide Web. ACM, 2001: 285-295.
- [12] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: Bayesian Personalized Ranking from Implicit Feedback [C] // Proceedings of the 25th Conference on Uncertainty in Artificial Intelligence. ACM, 2009: 452-461.
- [13] RENDLE S, FREUDENTHALER C, SCHMIDT-THIEME L. Factorizing Personalized Markov Chains for Next-basket Recommendation[C]//Proceedings of the 19th International Conference on World Wide Web. ACM, 2010: 811-820.
- [14] TAN Y, XU X, LIU Y. Improved Recurrent Neural Networks for Session-based Recommendations[C]//Proceedings of the 1st Workshop on Deep Learning for Recommender Systems. ACM, 2016: 17-22.
- [15] JANNACH D, LUDEWIG M. When Recurrent Neural Networks Meet the Neighborhood for Session-Based Recommendation[C]//Proceedings of the 11th ACM Conference on Recommender Systems. ACM, 2017: 306-310.
- [16] HIDASI B, KARATZOGLOU A. Recurrent Neural Networks with Top-k Gains for Session-based Recommendations [C] // Proceedings of the 27th ACM on Conference on Information and Knowledge Management. ACM, 2018: 843-852.
- [17] LI Z, ZHAO H, LIU Q, et al. Learning from History and Present: Next-item Recommendation via Discriminatively Exploiting User Behaviors[C] // Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2018: 1734-1743.
- [18] SONG Y, LEE J. Augmenting Recurrent Neural Networks with High-Order User-Contextual Preference for Session-Based Recommendation [EB/OL]. (2018-05-08) [2020-09-13]. <https://arxiv.org/abs/1805.02983>.
- [19] CUI Q, WU S, LIU Q, et al. MV-RNN: A Multi-View Recurrent Neural Network for Sequential Recommendation [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2020, 32: 317-331.
- [20] QIU R, LI J, HUANG Z, et al. Rethinking the Item Order in Session-based Recommendation with Graph Neural Networks [C]//Proceedings of the 28th ACM on Conference on Information and Knowledge Management. ACM, 2019: 579-588.
- [21] LIU L, WANG L, LIAN T. CaSe4SR: Using Category Sequence

Graph to Augment Session-based Recommendation [J/OL]. Knowledge-Based Systems, 2021, 212. https://www.researchgate.net/publication/346770323_CaSe4SR_Using_category_sequence_graph_to_augment_session-based_recommendation.

- [22] LE D, LAUW H, FANG Y. Modeling Contemporaneous Basket Sequences with Twin Networks for Next-Item Recommendation [C]//Proceedings of the 27th International Joint Conference on Artificial Intelligence. AAAI, 2018; 3414-3420.
- [23] VELICKOVIC P, CUCURULL G, CASANOVA A, et al. Graph Attention Networks [EB/OL]. (2018-02-04) [2020-09-13]. <https://arxiv.org/abs/1710.10903>.
- [24] CHEN W, CAI F, CHEN H, et al. A Dynamic Co-attention Network for Session-based Recommendation [C]// Proceedings of the 28th ACM on Conference on Information and Knowledge Management. ACM, 2019; 1461-1470.
- [25] LUDEWIG M, MAURO N, LATIFI S, et al. Empirical Analysis of Session-Based Recommendation Algorithms [J]. User Mode-

ling and User-adapted Interaction, 2021, 31; 149-181.



QIAO Jing-jing, born in 1993, Ph.D candidate, is a student member of China Computer Federation. Her main research interests include recommendation system and data mining.



WANG Li, born in 1971, Ph.D, professor, is a senior member of China Computer Federation. Her main research interests include big data computation and analysis, knowledge graph and data mining.

(责任编辑:喻藜)