

主题增强的多层次图神经网络会话推荐模型

唐 顾¹ 朱小飞¹

摘要 基于会话的推荐旨在基于会话内数据,为匿名或未登录用户做出推荐. 现有的研究工作通常仅以会话中单个商品作为最小单位进行建模,忽略商品在不同感受野下的表征. 同时,尚未挖掘会话序列中蕴含的商品隐式主题信息. 为了缓解上述问题,文中提出主题增强的多层次图神经网络会话推荐模型 (Topic-Enhanced Multi-level Graph Neural Network for Session-Based Recommendation, TEMGNN). 首先,设计多层次商品嵌入学习模块,拓宽商品的感受野,获取不同粒度下的商品表示. 然后,结合文中提出的多层次图神经网络进行同粒度和跨粒度下的商品信息传播,捕获更丰富的商品嵌入表征. 此外,提出商品主题学习模块,在不依赖任何商品属性信息的前提下,抽取商品在隐空间下的主题共性,并以显式的向量空间投影方式自动形成商品的主体表示,用于增强模型推荐性能. 在3个基准数据集上的实验表明,TEMGNN 的表现较优.

关键词 推荐系统, 图神经网络, 商品表示学习, 商品主题表示

引用格式 唐 顾,朱小飞. 主题增强的多层次图神经网络会话推荐模型. 模式识别与人工智能, 2023, 36(2): 174-186.

DOI 10.16451/j.cnki.issn1003-6059.202302006

中图法分类号 TP 391

Topic-Enhanced Multi-level Graph Neural Network for Session-Based Recommendation

TANG Gu¹, ZHU Xiaofei¹

ABSTRACT Session-based recommendation (SBR) aims to provide recommendations for anonymous users or users who are not logged in based on data in the session. The existing research models a single item in the session as the smallest unit, ignoring the item representation in different receptive fields. Moreover, the implicit topic information contained in the session sequence is not mined. To alleviate these issues, a topic-enhanced multi-level graph neural network (TEMGNN) for SBR is proposed. Firstly, a multi-level item embedding learning module is designed to broaden the receptive fields of item and obtain the representation of items at different granularities. Then, the proposed multi-level graph neural network is employed to propagate the item information with and cross granularities, capturing richer item embedding representation. Furthermore, a topic learning module is proposed to extract the topic commonalities of items in hidden space and automatically form topic representations of items by explicit vector space projection without relying on any item attribute information. Thus, the recommendation performance of the model is enhanced. Experiments on three benchmark datasets show the superiority of TEMGNN.

收稿日期:2022-09-29;录用日期:2023-02-28

Manuscript received September 29, 2022;

accepted February 28, 2023

本文责任编辑 梁吉业

Recommended by Associate Editor LIANG Jiye

国家自然科学基金项目 (No. 62141201)、重庆市自然科学基金项目 (No. CSTB2022NSCQ-MSX1672)、重庆市教育委员会

科学技术研究计划重大项目 (No. KJZD-M202201102) 资助

Supported by National Natural Science Foundation of China (No. 62141201), Natural Science Foundation of Chongqing (No. CSTB2022NSCQ-MSX1672), Major Project of Science and Technology Research Program of Chongqing Education Commission of China (No. KJZD-M202201102)

1. 重庆理工大学 计算机科学与工程学院 重庆 400054

1. College of Computer Science and Engineering, Chongqing University of Technology, Chongqing 400054

Key Words Recommendation System, Graph Neural Network, Item Representation Learning, Item Topic Representation

Citation TANG G, ZHU X F. Topic-Enhanced Multi-level Graph Neural Network for Session-Based Recommendation. *Pattern Recognition and Artificial Intelligence*, 2023, 36(2): 174–186.

基于会话的推荐 (Session-Based Recommendation, SBR) 旨在根据用户的短期历史行为预测用户最可能点击或购买的目标商品, 在一些视频流平台或电商平台 (如 Tiktok、YouTube 和淘宝等) 发挥着重要的作用. 基于会话的推荐主要为平台内的匿名用户或未登录用户进行个性化推荐, 这对提升新用户或未登录用户的平台使用体验和ación提高新用户的留存率起到至关重要的作用. 传统的推荐算法 (如协同过滤 (Collaborative Filtering, CF)^[1-3]、马尔科夫链 (Markov Chain, MC)^[4-5]) 依赖用户的长期行为记录或用户信息, 在用户行为较稀疏的会话推荐场景中性能会受到限制.

近年来, 基于深度学习的方法在基于会话的推荐任务中取得较好的效果^[6-10]. 这些方法的建模思路可大致分为以下2类.

1) 结合循环神经网络 (Recurrent Neural Network, RNN) 捕获会话中商品的顺序转换模式, 并结合注意力机制判断会话中不同商品的重要性. Hidasi 等^[6] 结合门控循环神经网络 (Gated Recurrent Unit, GRU)^[11], 模拟用户行为的顺序转换模式. 在此基础上, Li 等^[7] 提出 NARM (Neural Attention Recommendation Machine), 进一步结合注意力机制, 捕获用户偏好. Liu 等^[8] 提出 STAMP (Short-Term Attention/Memory Priority Model), 引入由多层感知机和注意力机制组成的短期记忆网络, 捕获用户的偏好. Ren 等^[12] 注意到用户兴趣漂移的问题, 进而提出 RepeatNet, 包含重复模块和探索模块, 重复模块预测用户的重复购买行为, 探索模块预测用户非重复购买行为. Chen 等^[13] 提出 DCN-SR (Dynamic Co-attention Network for Session-Based Recommendation), 利用共同注意力机制捕获用户的长期兴趣和短期兴趣. Yuan 等^[9] 提出 DSAN (Dual Sparse Attention Network for Session-Based Recommendation), 引入 α -entmax 函数, 改进注意力机制, 减少噪音商品对用户偏好的影响.

2) 应用图神经网络 (Graph Neural Network, GNN) 捕获会话中商品之间复杂的转换关系. Wu 等^[10] 提出 SR-GNN (Session-Based Recommendation with GNN), 将会话序列转换成会话图并结合门控图神经网络 (Gated GNN, GGNN)^[14], 建模会话中商品

之间的转换模式. Qiu 等^[15] 提出 FGNN (Fully GNN), 重新考虑会话中商品之间的转换关系, 并将推荐任务转换为图分类任务. 此外, Yu 等^[16] 提出 TAGNN (Target Attentive GNN), 设计目标感知的注意力模块, 进一步拓展 SR-GNN, 使其能够动态捕获用户意图. Wang 等^[17] 提出 SHARE (Session-Based Hypergraph Attention Network for Recommendation), 为每个会话构建超图, 并结合超图注意力网络动态聚合商品的上下文表示. Wang 等^[18] 提出 GCE-GNN (Global Context Enhanced GNN), 探索商品的全局上下文关系, 构建会话全局图, 并结合会话局部图和全局图, 学习用户的偏好表示. Xia 等^[19] 提出 COTREC (Self-Supervised Graph Co-training Framework for Session-Based Recommendation), 从自监督学习角度进一步挖掘会话表示, 结合基于自监督学习的联合训练, 进一步增强模型性能.

上述方法推动 SBR 的发展, 但上述工作都忽略一些值得挖掘的研究点. 首先, 现有方法大多以会话中的单个商品为最小单位进行建模并结合一些池化操作 (如平均池化、最大池化、注意力池化等) 以获取用户的偏好表示. 但是现有方法却忽略对商品不同感受野的建模. 以不同大小 (不同粒度) 的商品块为最小单位能够拓展商品的感受野和丰富商品的表征能力. 其次, 聚合同一商品在不同感受野的表征能够进一步增强商品的表征能力.

此外, 由于基于会话推荐的数据中往往缺乏商品的主题和类别信息, 导致现有方法都忽略建模这一信息. 直观上, 商品的部分嵌入表示能够在一定程度上反映商品间的相似程度, 这种特征可表征商品间的共性信息 (如主题信息或类别信息), 单独分离该类特征以显式的方式进行建模能够更好地捕获用户偏好. 所以显式的建模商品的主题信息能够使模型更加准确地捕捉用户偏好.

为了解决上述问题, 本文提出主题增强的多层次图神经网络会话推荐模型 (Topic-Enhanced Multi-level GNN for Session-Based Recommendation, TEMGNN). TEMGNN 主要由2个模块构成: 多层次商品嵌入学习模块、会话表示学习及推荐模块. 受 Guo 等^[20] 的启发, 利用多层次会话图结构捕获商品的多粒度表示, 并进行不同层次的图间信息聚合. 具体来

说,多层次商品嵌入学习模块包含三个子模块:1)多层次会话图结构;2)多层次图神经网络 (Multi-level GNN, ML-GNN);3)商品图间信息聚合.多层次商品嵌入学习模块可拓展会话中商品的感受野以捕获不同粒度下的商品信息,并同时依靠自身的语义信息形成对应的会话拓扑结构.然后结合 ML-GNN 学习各粒度下会话的拓扑结构信息,增强各粒度下的商品表示.最后,不同粒度下的商品表示进行信息交互,进一步丰富各粒度下的商品表示.另一方面,会话表示学习及推荐模块包含四个模块:商品主题学习模块、重复预测模块、探索预测模块和概率聚合模块.会话表示学习及推荐模块的目标是学习一个准确的会话表示,实现较优的推荐效果.本文提出一种主题学习模块,从商品的语义表示中抽取商品

的主题信息,并以一种显式的建模方式表征商品的主体信息,最后结合商品主题信息和注意力网络形成更精准的会话表示.在三个广泛使用的基准数据集进行的大量实验表明,TEMGNN 在相关评测指标上均较优.

1 主题增强的多层次图神经网络会话推荐模型

本文提出主题增强的多层次图神经网络会话推荐模型 (TEMGNN),整体架构如图 1 所示. TEMGNN 主要由两部分组成:多层次商品嵌入学习模块、会话表示学习及推荐模块.

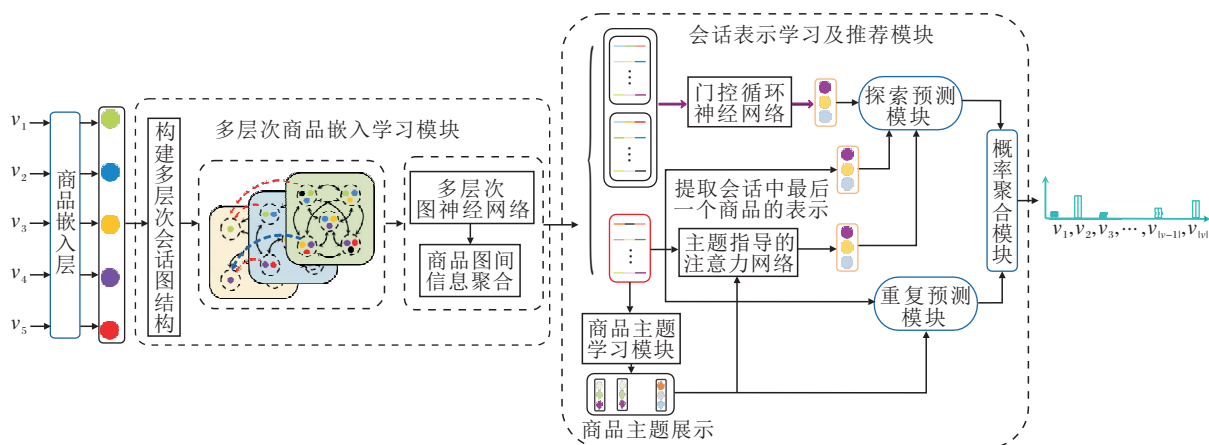


图 1 TEMGNN 的整体架构

Fig. 1 Framework of TEMGNN

1.1 问题定义

本节形式化定义基于会话的推荐任务以及文中出现的符号. 设

$$V = \{v_1, v_2, \dots, v_{|V|}\}$$

表示数据中出现的商品集合,其中 $|V|$ 为数据中非重复的商品数量,

$$S = (v_1^s, v_2^s, \dots, v_n^s)$$

表示会话序列,其中, n 为序列长度, v_i^s 表示用户在会话 S 中点击的第 i 个商品.

$$H_s = [h_1^s, h_2^s, \dots, h_n^s]$$

表示会话 S 在向量空间的嵌入表示,其中 $h_i^s \in \mathbf{R}^d$ 表示 v_i^s 在向量空间的嵌入表示.

基于会话的推荐目标是基于会话 S 为用户推荐用户下一次最可能点击的商品.

1.2 多层次商品嵌入学习模块

受 MSGIFSR (Multi-granularity Intent Heteroge-

neous Session Graph and Intent Fusion Ranking for Session-Based Recommendation)^[20] 的启发,多层次商品嵌入学习模块首先通过拓展会话中商品的感受野捕获不同粒度下的商品信息,并依靠其语义表示形成对应的会话拓扑结构.然后结合多层次图神经网络,聚合各粒度下的会话拓扑结构信息,用于增强各粒度下的商品表示.最后结合注意力机制进行商品的图间信息聚合.

1.2.1 多层次会话图结构

对于会话

$$S = (v_1^s, v_2^s, \dots, v_n^s),$$

利用滑动窗口拓展商品的感受野,获得不同粒度下的商品表示.具体来说,针对会话 S 中的 v_i^s ,定义以 v_i^s 为中心且窗口大小为 k 的商品块为

$$q_i^k = [v_{i-\lfloor \frac{k}{2} \rfloor}^s, \dots, v_i^s, \dots, v_{i+\lfloor \frac{k}{2} \rfloor}^s],$$

其中 $\lfloor \cdot \rfloor$ 为向下取整符。 q_i^k 对应向量空间的嵌入表示为

$$\mathbf{p}_i^k = \left[\mathbf{h}_{i-\lfloor \frac{k}{2} \rfloor}^s, \dots, \mathbf{h}_i^s, \dots, \mathbf{h}_{i+\lfloor \frac{k}{2} \rfloor}^s \right].$$

对 \mathbf{p}_i^k 进行平均池化,获得统一的嵌入表示

$$\bar{\mathbf{p}}_i^k = \text{MEAN}(\mathbf{p}_i^k) \in \mathbf{R}^d.$$

值得注意的是,当 $k=1$ 时, $\bar{\mathbf{p}}_i^k = \mathbf{h}_i^s$.

接下来,针对不同粒度下的商品表示构建其对应的会话图.对于粒度为 k 的会话序列向量表示

$$\bar{\mathbf{P}}^k = (\bar{\mathbf{p}}_1^k, \bar{\mathbf{p}}_2^k, \dots, \bar{\mathbf{p}}_n^k),$$

对应的会话图为

$$G_s^k = (v_s^k, \mathcal{E}_{i,j}^k),$$

其中, v_s^k 表示粒度为 k 的会话序列中所有商品, $e_{i,j}^k \in \mathcal{E}_{i,j}^k$ 表示商品 q_i^k, q_j^k 之间的连接强度,本文采用余弦相似度并结合归一化函数 Softmax 计算连接强度:

$$e_{i,j}^k = \frac{\exp(\mathcal{E}_{i,j}^k)}{\sum_{j=1}^n \exp(\mathcal{E}_{i,j}^k)},$$

其中

$$\mathcal{E}_{i,j}^k = \frac{\bar{\mathbf{p}}_i^{kT} \cdot \bar{\mathbf{p}}_j^k}{\|\bar{\mathbf{p}}_i^k\| \|\bar{\mathbf{p}}_j^k\|},$$

G_s^k 对应的邻接矩阵形式

$$A_s^k = \text{BMG}(\bar{\mathbf{P}}^k) \in \mathbf{R}^{n \times n},$$

不同粒度(不同 k)下的会话序列分别对应各自的图结构 G_s^k .由此构建多粒度会话图(Build Multi-level Session Graph, BMG).

值得注意的是,会话图的结构是由会话序列中商品的向量空间嵌入决定的,其结构可以随着图神经网络的层数叠加而动态更新.

1.2.2 多层次图神经网络

多层次图神经网络(ML-GNN)旨在捕获多粒度下会话图的拓扑结构信息以增强商品空间向量的表征能力.受LightGCN(Light Graph Convolution Network)^[21]的启发,移除传统图卷积网络(Graph Convolutional Network, GCN)中的线性转换和非线性激活结构.具体来说,针对粒度为 k 的会话序列表示

$$\bar{\mathbf{P}}^{k,(l-1)} = (\bar{\mathbf{p}}_1^{k,(l-1)}, \bar{\mathbf{p}}_2^{k,(l-1)}, \dots, \bar{\mathbf{p}}_n^{k,(l-1)}),$$

定义在第 l 层图神经网络下节点 $\bar{\mathbf{p}}_i^{k,(l-1)}$ 的图传播方式为:

$$A_s^{k,(l-1)} = \text{BMG}(\bar{\mathbf{P}}^{k,(l-1)}),$$

$$\bar{\mathbf{p}}_i^{k,(l)} = A_{i,s}^{k,(l-1)} (\bar{\mathbf{p}}_1^{k,(l-1)}, \bar{\mathbf{p}}_2^{k,(l-1)}, \dots, \bar{\mathbf{p}}_n^{k,(l-1)}),$$

其中,

$$\bar{\mathbf{P}}^{k,(l)} = (\bar{\mathbf{p}}_1^{k,(l)}, \bar{\mathbf{p}}_2^{k,(l)}, \dots, \bar{\mathbf{p}}_n^{k,(l)})$$

为经过第 l 层GCN后的第 k 个粒度下的会话序列表示.

值得注意的是,当 $l=1$ 时, $\bar{\mathbf{P}}^{k,(l-1)} = \bar{\mathbf{P}}^k$.同时, $A_s^{k,(l-1)}$ 的结构是由经过第 $l-1$ 层GCN后的第 k 个粒度下的会话序列 $\bar{\mathbf{P}}^{k,(l-1)}$ 表示决定的,这意味着 $A_s^{k,(l-1)}$ 会随着GCN层数的增加而不断更新,使会话图结构更加准确.

1.2.3 商品图间信息聚合

经过ML-GNN后,各粒度下的商品表示聚合各自的会话拓扑结构信息.然而以什么样的方式将多粒度下的商品表示进行聚合以形成一个综合的商品表示是一个值得探索的问题.一个简单直接的思路为:将同一商品在不同粒度下的表示构建子图,并依靠该子图结合GCN进行同一商品在不同粒度下的信息传播.然而该方式适用于子图节点数量较多(即 k 值较大)的情况,否则容易出现过度平滑的现象,从而降低模型性能.由于会话数据较稀疏,窗口大小 k 值太大会导致其对应的会话图 G_s^k 过于稀疏,从而使会话中的商品表示趋于一致的情况(即过度平滑问题).

为了解决上述问题,本文对商品在不同粒度下的表示进行区分.具体来说,将窗口大小 $k > 2$ 对应的会话序列表示结合注意力机制进行聚合,形成会话的粗粒度表示.再结合门控机制融合会话的粗粒度表示和细粒度表示(即 $k=1$ 对应的会话序列表示),形成会话的综合序列表示.上述过程的公式化定义如下:

$$\mathbf{h}_i^{s,c} = \sum_{j=2}^k \alpha_j \bar{\mathbf{p}}_i^{j,(l)} \in \mathbf{R}^d,$$

$$\alpha_j = \frac{\exp(\mathbf{w}_p^T \bar{\mathbf{p}}_i^{j,(l)})}{\sum_{j=2}^k \exp(\mathbf{w}_p^T \bar{\mathbf{p}}_i^{j,(l)})},$$

其中, $\bar{\mathbf{p}}_i^{j,(l)} \in \mathbf{R}^d$ 表示第 $j(j \leq k)$ 个粒度下经过第 l 层多层次神经网络后会话序列表示 $\bar{\mathbf{P}}^{j,(l)}$ 中第 i 个商品的表示, $\mathbf{w}_p \in \mathbf{R}^d$ 表示可训练参数.

聚合窗口大小 $k > 2$ 后对应的粗粒度会话序列表示为

$$\mathbf{H}_s^c = (\mathbf{h}_1^{s,c}, \mathbf{h}_2^{s,c}, \dots, \mathbf{h}_n^{s,c}).$$

接下来,本文结合门控机制,对粗粒度会话序列表示和细粒度会话序列表示进行特征聚合:

$$\tilde{\mathbf{h}}_i^s = g_i \odot \mathbf{h}_i^s + (1 - g_i) \odot \mathbf{h}_i^{s,c},$$

其中,

$$g_i = \sigma(\mathbf{w}_g^T([\mathbf{h}_i^s; \mathbf{h}_i^{s,c}])),$$

$\mathbf{w}_g \in \mathbf{R}^d$ 表示可训练参数, σ 表示激活函数Sigmoid.

聚合粗粒度和细粒度会话序列表示后的会话综合表示为:

$$\tilde{\mathbf{H}}_s = (\tilde{\mathbf{h}}_1^s, \tilde{\mathbf{h}}_2^s, \dots, \tilde{\mathbf{h}}_n^s).$$

1.3 会话表示学习及推荐模块

通过多层次图神经网络和商品图间信息聚合,商品的嵌入表示聚合丰富的特征. 本节详细介绍如何从商品的嵌入表示中学习用户的偏好表示以进行精确推荐. 会话表示学习及推荐模块由 4 个子模块组成:商品主题学习模块、重复预测模块、探索预测模块和概率聚合模块.

1.3.1 商品主题学习模块

在推荐场景中,许多商品或短视频都归属于同一主题或同一类别下,在基于会话的推荐场景中,由于这类数据往往缺乏对商品主题或类别的显式描述,现有工作都忽略对该类信息的建模. 针对这一问题,本文提出商品主题模块,用于建模商品的主题信息. 具体来说,商品主题模块从商品的语义表示中抽取商品的主题信息,并以一种显式的建模方式表征商品的主题信息.

首先,对于会话序列表示

$$\tilde{\mathbf{H}}_s = (\tilde{\mathbf{h}}_1^s, \tilde{\mathbf{h}}_2^s, \dots, \tilde{\mathbf{h}}_n^s),$$

本文结合双向门控循环神经网络 (Bidirectional GRU, Bi-GRU) 生成会话中商品 $\tilde{\mathbf{h}}_i^s$ 的主题待分配状态:

$$\begin{aligned} \mathbf{c}_i^s &= \vec{\mathbf{h}}_i^s + \overleftarrow{\mathbf{h}}_i^s \in \mathbf{R}^L, \\ \vec{\mathbf{h}}_i^s &= \overrightarrow{GRU}(\tilde{\mathbf{h}}_{i-1}^s, \tilde{\mathbf{h}}_i^s, \boldsymbol{\theta}_{gru}), \\ \overleftarrow{\mathbf{h}}_i^s &= \overleftarrow{GRU}(\tilde{\mathbf{h}}_{i+1}^s, \tilde{\mathbf{h}}_i^s, \boldsymbol{\theta}_{gru}), \end{aligned}$$

其中, $\boldsymbol{\theta}_{gru} \in \mathbf{R}^{d \times L}$ 表示可训练参数, L 为超参数, 表示商品主题的数量.

接下来,运用归一化函数 *Softmax* 将商品的主题待分配状态 \mathbf{c}_i^s 转换为商品主题概率分布:

$$q_{i,r}^s = \frac{\exp(\mathbf{c}_{i,r}^s)}{\sum_{j=1}^L \exp(\mathbf{c}_{i,j}^s)},$$

其中, $\mathbf{q}_i^s \in \mathbf{R}^L$, $q_{i,r}^s$ 为 \mathbf{q}_i^s 中的第 r ($r \leq L$) 个元素, 表示 v_i^s 属于第 r 个主题的概率.

将 \mathbf{q}_i^s 中最大值的索引通过独热向量 \mathbf{t}_i^s 表示商品的主题:

$$\mathbf{t}_i^s = \text{one-hot}(\arg \max \mathbf{q}_i^s) \in \mathbf{R}^L. \quad (1)$$

\mathbf{t}_i^s 表示会话 S 中第 i 个商品 v_i^s 所属的主题独热向量. 由于 $\arg \max$ 操作是不可微的过程,无法通过随机梯

度下降进行优化. 为了解决该问题,引入温度参数,重写 *Softmax* 函数^[22-23],使 \mathbf{q}_i^s 映射至连续的向量空间并逼近其独热表示:

$$t_{i,r}^s \approx \tilde{t}_{i,r}^s = \frac{\exp\left(\frac{q_{i,r}^s}{\tau}\right)}{\sum_{j=1}^L \exp\left(\frac{q_{i,j}^s}{\tau}\right)}, \quad (2)$$

其中, $t_{i,r}^s$ 为 $\mathbf{t}_i^s \in \mathbf{R}^L$ 的第 r 个元素, $\tilde{t}_{i,r}^s$ 为 $\tilde{\mathbf{t}}_i^s \in \mathbf{R}^L$ 的第 r 个元素. 值得注意的是,当 $\tau \rightarrow 0$ 时,式(2)等价于式(1).

为了解决模型训练和推理过程中由于温度参数 τ 带来差异,本文在模型训练阶段采用式(2)优化模型,在模型推理过程中采用式(1)进行模型推理. 其公式化定义为

$$\mathbf{t}_i^s = \begin{cases} \tilde{\mathbf{t}}_i^s, & \text{训练阶段} \\ \mathbf{t}_i^s, & \text{推理阶段} \end{cases}$$

获得商品的主题独热向量 \mathbf{t}_i^s 后,结合 GRU 捕获主题上下文信息:

$$\begin{aligned} \hat{\mathbf{t}}_i^s &= \mathbf{W}_l \mathbf{t}_i^s + \mathbf{b}_l, \\ \bar{\mathbf{t}}_i^s &= GRU(\hat{\mathbf{t}}_{i-1}^s, \hat{\mathbf{t}}_i^s, \boldsymbol{\phi}_{gru}), \\ \bar{\bar{\mathbf{t}}}_i^s &= \sigma(\mathbf{W}_a \bar{\mathbf{t}}_i^s + \mathbf{b}_a), \end{aligned}$$

其中, $\mathbf{b}_l \in \mathbf{R}^d$, $\mathbf{b}_a \in \mathbf{R}^d$ 为可训练参数, σ 为激活函数 \tanh , $\mathbf{W}_l \in \mathbf{R}^{d \times L}$, $\mathbf{W}_a \in \mathbf{R}^{d \times d}$.

会话序列 S 对应的主题序列表示为

$$\mathbf{T}_s = (\bar{\bar{\mathbf{t}}}_1^s, \bar{\bar{\mathbf{t}}}_2^s, \dots, \bar{\bar{\mathbf{t}}}_n^s),$$

其中 $\bar{\bar{\mathbf{t}}}_i^s \in \mathbf{R}^d$.

1.3.2 重复预测模块

对于一些用户比较感兴趣的商品往往存在一定比例的重复点击或重复购买. 受 RepeatNet^[12] 的启发,结合会话的综合序列表示

$$\tilde{\mathbf{H}}_s = (\tilde{\mathbf{h}}_1^s, \tilde{\mathbf{h}}_2^s, \dots, \tilde{\mathbf{h}}_n^s)$$

和会话的主题序列表示

$$\mathbf{T}_s = (\hat{\mathbf{t}}_1^s, \hat{\mathbf{t}}_2^s, \dots, \hat{\mathbf{t}}_n^s),$$

对用户点击或购买过的商品进行打分:

$$y_i^r = \begin{cases} z_i, & v_i \in S \\ 0, & v_i \notin S \end{cases}$$

$$z_i = \frac{\exp\left(\mathbf{w}_r^T (\tilde{\mathbf{h}}_i^s + \bar{\bar{\mathbf{t}}}_i^s)\right)}{\sum_{j=1}^n \exp\left(\mathbf{w}_r^T (\tilde{\mathbf{h}}_j^s + \bar{\bar{\mathbf{t}}}_j^s)\right)},$$

其中, $\mathbf{w}_r \in \mathbf{R}^d$ 表示可训练参数, $\mathbf{y}^r \in \mathbf{R}^{|V|}$ 表示重复预测概率分布, \mathbf{y}^r 只对在当前会话 S 中出现过的商品进行打分, 未出现的商品的得分为 0.

1.3.3 探索预测模块

在电商平台或视频流平台, 非重复购买和点击行为占据相当一部分的用户习惯. 因此, 建模用户的整体偏好并推荐他们未购买或点击过且感兴趣的商品十分重要.

商品的主题或类别信息往往能够反映用户的整体偏好, 所以本文将主题序列表示

$$\mathbf{T}_s = (\hat{\mathbf{t}}_1, \hat{\mathbf{t}}_2, \dots, \hat{\mathbf{t}}_n)$$

以注意力机制的形式指导会话的综合序列表示:

$$\tilde{\mathbf{H}}_s = (\tilde{\mathbf{h}}_1^s, \tilde{\mathbf{h}}_2^s, \dots, \tilde{\mathbf{h}}_n^s).$$

聚合形成用户的整体偏好:

$$\mathbf{s}_l = \sum_{i=1}^n \beta_i \mathbf{x}_i^s,$$

$$\beta_i = \frac{\exp(\mathbf{w}_\beta^T \mathbf{x}_i^s)}{\sum_{j=1}^n \exp(\mathbf{w}_\beta^T \mathbf{x}_j^s)},$$

$$\mathbf{x}_i^s = \sigma(\mathbf{W}_h \tilde{\mathbf{h}}_i^s + \mathbf{W}_l \bar{\mathbf{t}}_i^s),$$

其中, $\mathbf{W}_h \in \mathbf{R}^{d \times d}$, $\mathbf{W}_l \in \mathbf{R}^{d \times d}$ 表示可训练参数, $\mathbf{w}_\beta \in \mathbf{R}^d$.

用户的粗粒度兴趣对于用户的整体偏好的建模往往能起到一定的补充作用. 同时, 会话中的最后一个商品点击往往能反映用户的即时兴趣. 因此将粗粒度会话序列表示

$$\mathbf{H}_s^c = (\mathbf{h}_1^{s,c}, \mathbf{h}_2^{s,c}, \dots, \mathbf{h}_n^{s,c})$$

结合 GRU, 获取用户的粗粒度偏好 \mathbf{s}_c .

同时, 将会话综合序列中的最后一个商品表示

$\tilde{\mathbf{h}}_n^s$ 作为用户的即时偏好 \mathbf{s}_l .

最后, 本文融合 \mathbf{s}_l , \mathbf{s}_c 和 \mathbf{s}_l , 获取用户最终的偏好表示 \mathbf{s}_f . 该过程定义如下:

$$\tilde{\mathbf{h}}_i^{s,c} = \text{GRU}(\mathbf{h}_{i-1}^{s,c}, \mathbf{h}_i^{s,c}, \boldsymbol{\phi}_c),$$

其中 $\boldsymbol{\phi}_c \in \mathbf{R}^{d \times d}$ 表示可训练参数.

本文取经过 GRU 后的粗粒度会话序列表示

$$\tilde{\mathbf{H}}_s^c = (\tilde{\mathbf{h}}_1^{s,c}, \tilde{\mathbf{h}}_2^{s,c}, \dots, \tilde{\mathbf{h}}_n^{s,c})$$

中最后一个商品表示 $\tilde{\mathbf{h}}_n^{s,c}$ 作为用户的粗粒度偏好表示 \mathbf{s}_c . 最后融合 \mathbf{s}_l , \mathbf{s}_c 和 \mathbf{s}_l , 获取用户最终的偏好表示:

$$\mathbf{s}_f = \mathbf{s}_l + \delta \mathbf{s}_c + \mathbf{s}_l,$$

其中 δ 为控制粗粒度用户偏好表示信息量的超

参数.

接下来, 结合用户的最终偏好表示 \mathbf{s}_f 对用户未点击或购买的商品进行概率分布的预测:

$$y_i^e = \frac{\exp(\boldsymbol{\rho}_i)}{\sum_{j=1}^{|V|} \exp(\boldsymbol{\rho}_j)},$$

$$\boldsymbol{\rho}_i = \begin{cases} \mathbf{s}_f^T \mathbf{h}_i, & v_i \notin S \\ \mathbf{0}, & v_i \in S \end{cases}$$

其中, $\mathbf{h}_i \in \mathbf{R}^d$ 为商品集合 V 中的第 i 个商品的嵌入表示, $\mathbf{y}^e \in \mathbf{R}^{|V|}$ 为探索预测概率分布, \mathbf{y}^e 仅对未出现在会话 S 中的商品进行打分.

1.3.4 概率聚合模块

通过重复推荐模块和探索推荐模块分别获取重复预测概率分布 \mathbf{y}^r 和探索预测概率分布 \mathbf{y}^e . 以用户最终的偏好表示 \mathbf{s}_f 生成门控结构, 融合 \mathbf{y}^r 和 \mathbf{y}^e , 生成最终的预测概率分布:

$$\hat{\mathbf{y}}_i = f_i \odot \mathbf{y}_i^r + (1 - f_i) \odot \mathbf{y}_i^e,$$

$$f_i = \sigma(\mathbf{w}_f^T \mathbf{s}_f),$$

其中, $\mathbf{w}_f \in \mathbf{R}^d$ 为可训练参数, $\hat{\mathbf{y}} \in \mathbf{R}^{|V|}$ 为最终的预测概率分布.

为了提升模型的泛化性, 采用 Madry 等^[24] 提出的 PGD (Projected Gradient Descent), 对模型参数添加对抗性扰动, 提升模型的泛化性. 具体来说, 在商品嵌入上添加对抗性扰动, 扰动量

$$\delta_{t+1} = \prod_{\|\delta\|_F \leq \epsilon} \left(\delta_t + \frac{\alpha g(\delta_t)}{\|g(\delta_t)\|_F} \right),$$

$$g(\delta_t) = \nabla_{\delta} L(f_{\theta}(X + \delta_t), y),$$

其中, t 为 PGD 的迭代步数, 设置为 2, $g(\delta_t)$ 为 δ_t 对应的参数梯度, X 为商品嵌入, f_{θ} 为模型参数.

$\prod_{\|\delta\|_F \leq \epsilon}$ 为将 δ 在以 ϵ 为半径的球面上进行投影以控制 δ 的范围.

最后, 利用交叉熵函数 L 作为损失函数, 对模型进行优化:

$$L = - \sum_{i=1}^{|V|} y_i \log_2(\hat{y}_i) + (1 - y_i) \log_2(1 - \hat{y}_i),$$

其中, y_i 为标签商品的独热向量表示, \hat{y}_i 为用户点击第 i 个商品的预测概率.

2 实验及结果分析

为了验证 TEMGNN 的有效性, 进行相关实验, 回答如下问题:

1) TEMGNN 性能是否超越目前最优模型?

2) TEMGNN 的每个模块对模型整体性能的影响怎样?

3) TEMGNN 在不同长度的会话上表现如何?

4) 不同层数的多层次图神经网络对模型性能的影响?

5) TEMGNN 训练过程中的时间和空间消耗情况怎样?

2.1 实验数据集

与之前的工作一样^[9,16,25-26], 本文选择广泛使用的基准数据集 Diginetica、Yoochoose、Retailrocket, 验证 TEMGNN 和基线模型的性能。

Diginetica 数据集来自 2016 CIKM Cup. Yoochoose 数据集来自 2015 RecSys Challenge, 由于数据量过大, 与之前工作一样, 将 Yoochoose 进行拆分, 分别取其最后的 1/64 和 1/4 部分构造新的数据, 并命名为“Yoochoose1/64”和“Yoochoose1/4”。类似地, 取 Retailrocket 数据集的最后 1/4 部分数据作为 Retailrocket 数据集的训练数据. 数据集统计信息如表 1 所示。

表 1 数据集统计信息

Table 1 Statistics of dataset

名称	训练会话数量	测试会话数量	商品数量	会话平均长度
Diginetica	719470	60858	43097	5.12
Yoochoose1/64	369859	55898	16766	6.16
Yoochoose1/4	5917745	55898	29618	7.42
Retailrocket	175325	24283	22305	3.96

与文献[9]和文献[15]一样, 滤除会话长度小于 2 的会话和会话中商品出现次数小于 5 的商品, 同时进行序列增强以扩增数据, 具体来说, 对于会话

$$S = (v_1^s, v_2^s, \dots, v_n^s),$$

生成序列和对应的标签:

$$([v_1^s], v_2^s), ([v_1^s, v_2^s], v_3^s), \dots, ([v_1^s, v_2^s, \dots, v_{n-1}^s], v_n^s).$$

2.2 基线模型

为了验证 TEMGNN 的整体表现, 选择如下 11 种基线模型进行性能对比, 基线模型可大致分为如下 3 类。

1) 基于传统方法的模型。

(1) 文献[1]模型. 依赖协同过滤, 为用户推荐与当前会话中商品最相似的商品。

(2) FPMC (Factorized Personalized Markov Chains)^[4]. 结合矩阵分解和马尔科夫链, 模拟用户行为的顺序转换关系。

2) 基于 RNN 和注意力机制的模型。

(1) 文献[6]模型. 应用 GRU 模拟用户的顺序行为, 并利用会话批量训练和排序损失函数优化模型。

(2) NARM^[7]. 使用 RNN 和注意力机制捕获用户的主要偏好。

(3) STAMP^[8]. 使用注意力机制替换 RNN 编码器, 并提取会话中最后一个商品的表示作为用户的短期兴趣。

(4) DSAN^[9]. 利用双稀疏注意网络完成会话推荐任务. 首先探索会话中每个商品之间的相互作用, 并通过注意力网络学习目标商品的表征. 然后, 应用一个普通的注意力网络获取当前会话中商品的重要性, 从而获得会话表示。

3) 基于 GNN 的模型。

(1) SR-GNN^[10]. 将会话序列转换成会话图结构并结合 GGNN^[14] 学习会话表示。

(2) TAGNN^[16]. 在 SR-GNN 的基础上引入目标注意力模块, 用于揭示给定目标商品与用户的历史点击商品的相关性, 从而改进会话推荐性能。

(3) SHARE^[17]. 为每个会话构建一个超图, 并结合超图注意力网络动态聚合商品的上下文表示。

(4) GCE-GNN^[18]. 从全局角度和局部角度构建商品之间的拓扑关系, 并结合图注意力网络学习会话中商品的表示。

(5) COTREC^[19]. 将自监督学习与基于会话推荐的联合训练相结合. 在联合训练中, 利用会话的内/外部关联性, 扩展两种不同的视图, 即商品视图和会话视图。

2.3 参数设置

在 TEMGNN 中, 设置训练批次大小为 512, 商品嵌入大小为 256, 多层次图结构中窗口数为 3, 窗口大小分别为 1, 2 和 3, 多层次图神经网络的层数为 1, 商品主题数量 $L = 512$. 与之前的工作一样^[9,14,16], 模型参数按照均值为 0、方差为 0.1 的高斯分布进行初始化. 优化器选择为 Adam (Adaptive Moment Estimation), 学习率设置为 0.001, 本文设置每经过 3 轮训练, 学习率衰减为原来的 0.1 倍. 值得注意的是, 进行消融实验时, 未被改变或替换的部分保持原始参数不变。

2.4 评测指标

与之前的工作中一样^[15-16,25,27-28], 采用两个广泛使用的评测指标 P@20 和 MRR@20 验证模型性能。

1) P@K. 准确率 (Precision, P) 衡量目标商品在召回列表中的样本比例:

$$P@K = \frac{n_{\text{hit}}}{N},$$

其中, n_{hit} 为目标商品在 Top- K 召回列表中的样本数量, N 为样本总数量。

2) MRR@ K . MRR (Mean Reciprocal Rank) 衡量目标商品在召回列表中的位置, 位置越靠前, 得分越高, 则

$$\text{MRR}@K = \frac{1}{N} \sum_{i=1}^N \frac{1}{\text{rank}_i},$$

其中, rank_i 为第 i 个目标商品在 Top- K 召回列表中的位置, N 为样本总数量。

2.5 对比实验

TEMGNN 与所有基线模型在 3 个基准数据集上的性能对比如表 2 所示, 表中 * 表示显著性检验, $p \leq 0.01$, 黑体数字表示最优值, 斜体数字表示次优值。由表可以看出, 在传统推荐模型中, 文献[1]模型的表现优于 FPMC, 这表明会话中商品间的共现关系是一种重要的信息。

相比基于传统方法的模型, 基于神经网络的模型性往往表现更优。文献[6]模型将 RNN 应用于会话推荐任务中, 在大多数数据上的表现都优于传统方法, 这显示出 RNN 建模序列信息的能力。NARM

和 STAMP 的性能均优于文献[6]模型, 这是由于它们引入注意力机制以捕获用户的主要偏好。DSAN 在基于 RNN 和注意力机制的模型中的性能表现最优, 这是由于 DSAN 设计双重稀疏注意力网络, 缓解会话中噪音商品对建模用户偏好的影响。

在所有基线模型中, 基于 GNN 的模型性能表现最优。SR-GNN 根据会话中商品之间的转换关系将会话转化为图结构, 捕获商品间的隐式连接关系, 且进一步结合 GGNN 学习会话表示。TAGNN 在 SR-GNN 基础之上添加目标感知注意力模块, 进一步考虑用户的动态偏好。COTREC 与 SR-GNN 的性能表现相当, 通过商品的内/外部连接获得商品在不同视图下的表示, 在一定程度上缓解数据稀疏的问题。在所有基于 GNN 的基线模型当中, GCE-GNN 的表现最优, 这是由于 GCE-GNN 有效学习商品在局部角度和全局角度下的转换关系, 同时进一步结合反向位置嵌入, 更好地建模商品的位置信息。

TEMGNN 在 3 个基准数据集上的性能优于 GCE-GNN。主要原因为 TEMGNN 提出多层次图神经网络和商品主题学习模块, 用于捕获不同粒度下的商品表示和商品主题表示。

表 2 各模型在 4 个数据集上的指标值

Table 2 Index values of different models on 4 datasets

模型	Diginetica		Yoochoose1/64		Yoochoose1/4		Retailrocket	
	P@20	MRR@20	P@20	MRR@20	P@20	MRR@20	P@20	MRR@20
文献[1]模型	35.75	11.57	51.60	21.81	52.31	21.70	10.23	3.96
FPMC	22.14	6.66	45.62	15.01	51.86	17.50	9.65	4.32
文献[6]模型	30.79	8.22	60.64	22.89	59.53	22.60	41.35	25.54
NARM	48.32	16.00	68.32	28.63	69.73	29.23	59.46	41.48
STAMP	46.62	15.13	68.74	29.67	70.44	30.00	58.48	38.96
DSAN	53.76	18.99	69.68	31.23	72.06	32.22	62.56	42.39
SR-GNN	51.26	17.78	70.57	30.94	71.36	31.89	60.19	39.64
TAGNN	51.31	18.03	<i>71.02</i>	31.12	71.32	<i>32.11</i>	59.31	39.65
SHARE	52.73	18.05	71.51	<i>31.45</i>	72.25	<i>32.11</i>	63.22	43.82
COTREC	54.18	<i>19.07</i>	70.72	29.36	70.48	29.19	<i>63.81</i>	<i>44.48</i>
GCE-GNN	54.22	19.04	70.91	30.63	71.40	31.49	63.29	40.35
TEMGNN	55.31*	19.91*	71.88*	31.46*	<i>72.23*</i>	32.56*	65.78*	45.68*
提升率/%	2.01	4.40	1.21	0.03	-	1.40	3.08	2.70

2.6 消融实验

为了验证 TEMGNN 中商品多粒度表示、多层次图神经网络 (ML-GNN) 和商品主题模块的有效性, 本文设计如下变种模型。

1) TEMGNN-SG. 在多层次会话图结构中仅保

留窗口大小为 1 的会话图结构, 即去除商品的多粒度表示。

2) TEMGNN-MLP. ML-GNN 替换为多层感知机 (Multi-layer Perception, MLP)。

3) TEMGNN-GGNN. ML-GNN 替换为 SR-GNN

中的 GGNN. 同时, 会话图结构的构造方式与 SR-GNN 保持一致.

4) TEMGNN-GAT. ML-GNN 替换为 GCE-GNN 中的图注意力网络 (Graph Attention Network, GAT). 同时, 会话图结构的构造方式与 GCE-GNN 保持一致.

5) TEMGNN-w/o Topic. 移除 TEMGNN 中的商品主题学习模块, 同时主题指导的注意力网络替换为自注意力网络.

各变种模型的性能对比如表 3 所示. 由表可观察到, 仅保留多层次图结构中窗口大小为 1 的会话图结构 (TEMGNN-SG) 会导致模型性能下降, 这验证不同粒度下的商品表示能够优势互补, 使商品表示更加准确. 同时, 将 ML-GNN 替换为 MLP、GGNN、

GAT 均会导致模型性能受到消极影响. 具体来说, TEMGNN-GGNN 与 TEMGNN-MLP 表现相当, 这是由于 TEMGNN-GGNN 未能区分会话图中商品间的连接强度. TEMGNN-GAT 的表现更优, 这是由于 GAT 能够自适应地学习商品间的连接强度, 但是依然根据会话中商品间的转换关系生成会话的拓扑结构, 无法避免会话图中由于用户错点或误点带来的噪音信息. TEMGNN 可以根据商品间的语义关系自适应地生成会话对应的图结构, 在一定程度上规避由于用户的错点或误点带来的消极影响. 另一方面, 当移除商品主题学习模块 (TEMGNN-w/o Topic) 时, 模型的表现呈现稳定下降, 这验证商品主题学习模块能够为商品提供有效的主题信息.

表 3 不同模块的消融实验结果

Table 3 Results of ablation experiment of different modules

模型	Diginetica		Yoochoose1/64		Retailrocket	
	P@20	MRR@20	P@20	MRR@20	P@20	MRR@20
TEMGNN-SG	53.65	19.11	70.66	30.25	60.56	44.43
TEMGNN-MLP	53.08	19.45	71.15	31.04	61.19	44.01
TEMGNN-GGNN	52.94	19.51	71.33	31.10	62.58	44.32
TEMGNN-GAT	54.88	19.74	71.56	31.22	64.77	45.25
TEMGNN-w/o Topic	54.98	19.45	71.60	31.28	65.10	45.32
TEMGNN	55.31	19.91	71.88	31.46	65.78	45.68


2.7 在不同长度会话上的性能

为了验证 TEMGNN 在不同长度会话上的性能, 本文将会话分为 2 组: 会话长度小于 5 的称为短会话, 会话长度大于等于 5 的称为长会话. 将 TEMGNN 与 COTREC 和 GCE-GNN 在上述两种会话上进行实验, 结果如图 2 所示.


由图 2 可以得出如下结论.

1) 3 种模型在短会话上的性能优于在长会话上的性能. 该现象说明长会话包含用户更多的兴趣转换, 导致模型难以捕获用户的主要意图.

2) TEMGNN 在各数据集的长会话和短会话上性能均优于 GCE-GNN 和 COTREC, 这说明 TEM-GNN 不论在长会话和短会话上都具有明显改进.




(a1) P@20




(a2) MRR@20

(a) Diginetica




(b1) P@20




(b2) MRR@20

(b) Yoochoose1/64




(c1) P@20




(c2) MRR@20

(c) Yoochoose1/4



(d1) P@20



(d2) MRR@20

(d) Retailrocket

图 2 不同模型在不同长度会话上的表现

Fig. 2 Performance of different models on different length sessions

2.8 层数对多层次神经网络性能的影响

为了验证多层次神经网络 (ML-GNN) 层数对 TEMGNN 性能的影响,将 ML-GNN 的层数设置为 1, 2, 3, 4, 分别验证 TEMGNN 性能的变化,实验结果如图 3 所示。

由图 3 可以看出,TEMGNN 在 Diginetica、Retailrocket 数据集上性能最优的情况是当 ML-GNN 层数设置为 1 时,同时在 Yoochoose 数据集上性能最优的情况是当 ML-GNN 层数为 2。这是由于 Yoochoose 数据集上的会话平均长度长于 Diginetica、

Retailrocket 数据集上的长度,会话的拓扑结构更为复杂,需要更深层的 ML-GNN 学习拓扑信息.另一方面,由图可以看出,随着 ML-GNN 层数增加到 3 或 4

时,TEMGNN 的性能出现下降,这是由于 ML-GNN 层数过多会导致会话图中节点特征表示出现过度平滑的现象.




图 3 不同 ML-GNN 层数对 TEMGNN 性能的影响

Fig. 3 Effect of different ML-GNN layers on performance of TEMGNN

2.9 训练时间和空间复杂度分析

为了探索 TEMGNN 的实用性,对 TEMGNN 在训练过程中的耗时、收敛速度及内存消耗进行相关实验,结果如表 4 所示.

由表 4 可以看出,COTREC 耗时最多,TAGNN 内存消耗最多,这是由于 COTREC 引入自监督学习策略,TAGNN 由于需要对每条会话都计算所有候选

商品的注意力分数,导致空间复杂度偏高,内存消耗最多. TEMGNN 的耗时略高于 GCE-GNN,但大幅低于 COTREC.

另一方面,由于 TEMGNN 引入商品的多粒度表示,内存消耗略高于 GCE-GNN,但远低于 TA-GNN. 上述结论表明,TEMGNN 的时间复杂度和空间复杂度适中,具有潜在应用价值.

表 4 各模型的训练时间和空间复杂度分析

Table 4 Training time and spatial complexity analysis of different models

模型	Diginetica			Yoochoose1/64			Retailrocket		
	耗时/s	训练轮数	内存消耗/M	耗时/s	训练轮数	内存消耗/M	耗时/s	训练轮数	内存消耗/M
TAGNN	827	5	9745	331	7	8757	250	5	10621
GCE-GNN	152	6	2066	76	6	1699	20	5	2208
COTREC	1459	6	3085	961	6	3079	293	5	2305
TEMGNN	224	7	7055	121	7	6605	77	8	4068

3 结束语

不同感受野下的商品可能蕴含着不同的表征.同时,在缺乏显式的商品主题特征的情况下,商品本身的语义信息能够隐式地反映出该类特征.本文提出主题增强的多层次图神经网络会话推荐模型 (TEMGNN),结合多层次图神经网络进行不同感受

野下的商品信息传播,捕获更丰富的商品嵌入表征.同时,本文还提出在缺乏显式商品主题特征的情况下能够通过商品的语义表示隐式生成商品主题表示的商品主题学习模块.目前在基于会话的推荐领域,对于用户的错误点击或误点的识别是一大挑战.为此,下一步将考虑通过商品的全局上下文关系和局部上下文关系对用户的错误点击或误点进行判别并滤除.

参 考 文 献

- [1] SARWAR B, KARYPIS G, KONSTAN J, *et al.* Item-Based Collaborative Filtering Recommendation Algorithms // Proc of the 10th International Conference on World Wide Web. New York, USA: ACM, 2001: 285–295.
- [2] HERLOCKER J L, KONSTAN J A, TERVEEN L G, *et al.* Evaluating Collaborative Filtering Recommender Systems. ACM Transactions on Information Systems, 2004, 22(1): 5–53.
- [3] CHEN W Y, CAI F, CHEN H H, *et al.* Joint Neural Collaborative Filtering for Recommender Systems. ACM Transactions on Information Systems, 2019, 37(4). DOI: 10.1145/3343117.
- [4] RENDLE S, FREUDENTHALER C, SCHMIDT-THIEME L. Factorizing Personalized Markov Chains for Next-Basket Recommendation // Proc of the 19th International Conference on World Wide Web. New York, USA: ACM, 2010: 811–820.
- [5] SHANI G, HECKERMAN D, BRAFMAN R I. An MDP-Based Recommender System. Journal of Machine Learning Research, 2005, 6: 1265–1295.
- [6] HIDASI B, KARATZOGLOU A, BALTRUNAS L, *et al.* Session-Based Recommendations with Recurrent Neural Networks[C/OL]. [2022–09–20]. <https://arxiv.org/pdf/1511.06939.pdf>.
- [7] LI J, REN P J, CHEN Z M, *et al.* Neural Attentive Session-Based Recommendation // Proc of the ACM Conference on Information and Knowledge Management. New York, USA: ACM, 2017: 1419–1428.
- [8] LIU Q, ZENG Y F, MOKHOSI R, *et al.* STAMP: Short-Term Attention/Memory Priority Model for Session-Based Recommendation // Proc of the 24th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, USA: ACM, 2018: 1831–1839.
- [9] YUAN J H, SONG Z H, SUN M Y, *et al.* Dual Sparse Attention Network for Session-Based Recommendation. Proceedings of the 35th AAAI Conference on Artificial Intelligence, 2021, 35(5): 4635–4643.
- [10] WU S, TANG Y Y, ZHU Y Q, *et al.* Session-Based Recommendation with Graph Neural Networks // Proc of the 33rd AAAI Conference on Artificial Intelligence and 31st Innovative Applications of Artificial Intelligence Conference and 9th AAAI Symposium on Educational Advances in Artificial Intelligence. Palo Alto, USA: AAAI, 2019: 346–353.
- [11] CHO K, VAN MERRIENBOER B, GULCEHRE C, *et al.* Learning Phrase Representations Using RNN Encoder-Decoder for Statistical Machine Translation // Proc of the Conference on Empirical Methods in Natural Language Processing. Stroudsburg, USA: ACL, 2014: 1724–1734.
- [12] REN P J, LI J, CHEN Z M, *et al.* RepeatNet: A Repeat Aware Neural Recommendation Machine for Session-Based Recommendation // Proc of the 33rd AAAI Conference on Artificial Intelligence and 31st Innovative Applications of Artificial Intelligence Conference and 9th AAAI Symposium on Educational Advances in Artificial Intelligence. Palo Alto, USA: AAAI, 2019: 4806–4813.
- [13] CHEN W Y, CAI F, CHEN H H, *et al.* A Dynamic Co-attention Network for Session-Based Recommendation // Proc of the 28th ACM International Conference on Information and Knowledge Management. New York, USA: ACM, 2019: 1461–1470.
- [14] LI Y J, TARLOW D, BROCKSCHMIDT M, *et al.* Gated Graph Sequence Neural Networks[C/OL]. [2022–09–20]. <https://arxiv.org/pdf/1511.05493v4.pdf>.
- [15] QIU R H, LI J J, HUANG Z, *et al.* Rethinking the Item Order in Session-Based Recommendation with Graph Neural Networks // Proc of the 28th ACM International Conference on Information and Knowledge Management. New York, USA: ACM, 2019: 579–588.
- [16] YU F, ZHU Y Q, LIU Q, *et al.* TAGNN: Target Attentive Graph Neural Networks for Session-Based Recommendation // Proc of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA: ACM, 2020: 1921–1924.
- [17] WANG J L, DING K Z, ZHU Z W, *et al.* Session-Based Recommendation with Hypergraph Attention Networks // Proc of the SIAM International Conference on Data Mining. Philadelphia, USA: SIAM, 2021: 82–90.
- [18] WANG Z Y, WEI W, CONG G, *et al.* Global Context Enhanced Graph Neural Networks for Session-Based Recommendation // Proc of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA: ACM, 2020: 169–178.
- [19] XIA X, YIN H Z, YU J L, *et al.* Self-Supervised Graph Co-training for Session-Based Recommendation // Proc of the 30th ACM International Conference on Information and Knowledge Management. New York, USA: ACM, 2021: 2180–2190.
- [20] GUO J Y, YANG Y M, SONG X C, *et al.* Learning Multi-granularity Consecutive User Intent Unit for Session-Based Recommendation // Proc of the 15th ACM International Conference on Web Search and Data Mining. New York, USA: ACM, 2022: 343–352.
- [21] HE X N, DENG K, WANG X, *et al.* LightGCN: Simplifying and Powering Graph Convolution Network for Recommendation // Proc of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA: ACM, 2020: 639–648.
- [22] HE C Y, ANNAVARAM M, AVESTIMEHR S. Group Knowledge Transfer: Federated Learning of Large CNNs at the Edge // Proc of the 34th International Conference on Neural Information Processing Systems. Cambridge, USA: MIT Press, 2020: 14068–14080.
- [23] BENGIO Y, LÉONARD N, COURVILLE A. Estimating or Propagating Gradients Through Stochastic Neurons for Conditional Computation[C/OL]. [2022–09–20]. <https://arxiv.org/pdf/1308.3432.pdf>.
- [24] MADRY A, MAKELOV A, SCHMIDT L, *et al.* Towards Deep Learning Models Resistant to Adversarial Attacks[C/OL]. [2022–09–20]. <https://openreview.net/pdf?id=rJzIBZAb>.

[25] WANG M R, REN P J, MEI L, *et al.* A Collaborative Session-Based Recommendation Approach with Parallel Memory Modules // Proc of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA: ACM, 2019: 345–354.

[26] KANG W C, MCAULEY J. Self-Attentive Sequential Recommendation // Proc of the IEEE International Conference on Data Mining. Washington, USA: IEEE, 2018: 197–206.

[27] PAN Z Q, CAI F, CHEN W Y, *et al.* Star Graph Neural Networks for Session-Based Recommendation // Proc of the 29th ACM International Conference on Information and Knowledge Management. New York, USA: ACM, 2020: 1195–1204.

[28] LUO A J, ZHAO P P, LIU Y C, *et al.* Collaborative Self-Attention Network for Session-Based Recommendation // Proc of the 29th International Joint Conference on Artificial Intelligence. San Francisco, USA: IJCAI, 2020: 2591–2597.

作者简介



唐顾, 硕士研究生, 主要研究方向为推荐系统、自然语言处理. E-mail: Gutang@2020.cqut.edu.cn.

(TANG Gu, master student. His research interests include recommendation systems and natural language processing.)



朱小飞(通信作者), 博士, 教授, 主要研究方向为自然语言处理、数据挖掘、信息检索. E-mail: zxf@cqut.edu.cn.

(ZHU Xiaofei (Corresponding author), Ph. D., professor. His research interests include natural language processing, data mining and information retrieval.)

(上接 119 页)

二、来稿要求

1、作者通过《模式识别与人工智能》网站(<http://prai.hfcas.ac.cn>)“作者中心”一栏进行投稿。在线投稿时请详细提供联系人的联系方式(包括通讯地址、邮编、E-mail 地址和联系电话等)。请在论文标题后备注“(视频行为检测与识别)”。

2、稿件首页应包括:题目、真实姓名、详细工作单位、城市及邮政编码、中英文摘要、中英文关键词。中文摘要 200 字左右,英文摘要 200 词左右。关键词中英文应对应,3~5 条为宜。

3、来稿应是原创性论文,具有创新学术价值,有自己新的观点和见解,可推动或丰富该课题领域的研究与发展;或具有重大实用价值的创新开发成果。

4、来稿未在正式出版物发表过,且不存在一稿多投和抄袭现象。一经录用,未经同意,不得以任何形式、任何语言再次发表。作者文责自负。

三、重要日期

投稿截止日期 5 月 31 日

四、联系方式

电话 0551-65591176

E-mail bjb@iim.cas.cn