

doi: 10.12052/gdutxb.230212

基于因子级特征与属性偏好联合学习的会话推荐

林浩, 陈平华

(广东工业大学 计算机学院, 广东 广州 510006)

摘要: 针对序列短、数据稀疏、难以泛化导致的会话推荐准确率不高问题, 提出了因子级特征与属性偏好联合学习的会话推荐模型。模型首先通过构建全局级会话项目依赖感知图, 学习用户全局级会话项目嵌入; 然后, 应用解纠缠表示学习方法将会话中的项目分解为多个相对独立的因子级特征, 学习用户因子级兴趣偏好; 接着利用情境化自注意力神经网络捕获用户针对会话项目属性的偏好; 最后, 将因子级兴趣偏好与项目属性偏好联合学习, 得到用户最终兴趣偏好表示, 并最终完成会话推荐。在Diginetica、Cosmetics两个公开数据集上的多个实验表明, 本文模型优于对比的基线模型, 验证了本文模型的良好推荐性能和设计合理性。

关键词: 会话推荐; 因子级特征; 解纠缠表示; 全局项目依赖; 图神经网络

中图分类号: TP391

文献标志码: A

文章编号: 1007-7162(2024)06-0091-10

Factor-level Feature and Attribute Preference Joint Learning Based Session Recommendation

Lin Hao, Chen Ping-hua

(School of Computer Science and Technology, Guangdong University of Technology, Guangzhou 510006, China)

Abstract: A factor-level feature and attribute preference joint learning session-based recommendation model is proposed to address the problem of low recommendation accuracy caused by short sequences, sparse data, and difficulty in generalization. The model first learns user global-level session item embeddings by constructing a global level session item dependency perception graph. Then, using the method of disentanglement representation learning, the items in the conversation are decomposed into multiple relatively independent factor-level features to learn user factor-level interest preferences. Then, using contextualized self-attention graph neural networks, user preferences for session item attributes are captured. Finally, factor-level interest preferences and the project attribute preferences are jointly learned to obtain the user's final interest preferences, which in turn completes the session recommendation. Multiple experiments on two publicly available datasets, Diginetica and Cosmetics, have shown that our model outperforms the baseline model in comparison, verifying the recommendation performance and design rationality of our model.

Key words: session-based recommendation; factor-level feature; disentangled representation learning; global-level item dependency; graph neural network

随着互联网应用规模和互联网信息量的快速增长, 用户被各类纷繁复杂的互联网信息所困扰, 会话推荐^[1]逐渐成为了缓解信息过载的重要手段。会话指一段时间段内互联网用户收集和使用的一组项目(如产品、歌曲或电影), 会话推荐则是在给定当前会话上下文的前提下, 预测会话下一个可能出现的项

目。由于会话推荐场景中系统没有获取用户标识(用户未注册或登录), 既无法利用用户个人信息, 也不能获取用户长期历史行为序列, 只能尽可能地在有限的近期交互行为中对匿名用户的动态兴趣进行建模, 以此为用户提供实时、准确的推荐服务, 因此会话推荐面临如下挑战: (1) 用户的匿名性致使无法使

收稿日期: 2023-12-28

基金项目: 广东省重点领域研发计划项目(2021B0101200002); 广东省自然科学基金资助项目(2021A1515012233)

作者简介: 林浩(1998-), 男, 硕士研究生, 主要研究方向为图神经网络、推荐系统, E-mail: 1695942074@qq.com

通信作者: 陈平华(1967-), 男, 教授, 主要研究方向为人工智能、大数据, E-mail: phchen@gdut.edu.cn

用用户个人相关信息,如购买记录、统计人口信息等;(2)会话仅有一小段时间内产生的交互记录,存在行为数据稀疏和弱泛化性的特点。

早期的会话建模研究常采取基于序列规则的方法^[2-3],旨在挖掘会话用户-项目交互序列中频繁出现的项目集合,以此生成序列模式指导后续项目推荐。近年来,随着深度学习的兴起,深层神经网络模型开始广泛用于会话推荐^[4],越来越多的研究将图神经网络引入到会话推荐中,对会话中的用户兴趣表示进行建模^[5]。然而,它们大多只将当前会话的用户-项目交互序列简单地构建为一个独立的会话图,没有意识到当前会话中相对较短的序列仅仅是用户某一方面兴趣,忽略了不同会话之间的内在联系(会话级的

全局依赖),令模型陷入局部最优的窘境,无法有效地实现用户兴趣偏好的泛化。

总之,现有的会话推荐算法仅是将会话中的项目视为一个独立的整体,学习项目的嵌入(项目的特征),未能挖掘项目以下级别的更细粒度的依赖关系,如因子级特征之间的依赖关系。现实情况是用户购买意图可能会受到不同因素(因子)驱动。如图1所示,用户浏览的都是电子产品,经过一番交互后,用户选择购买了一部华为手机。在整个会话序列中,一个项目具有多个因子级特征,每个因子级特征相对独立且都可能影响用户的最终决策。从图1所示的会话来看,华为品牌这个因子对用户购买行为影响很大。




图1 项目因子级特征对用户购买行为的影响

Fig.1 An example to illustrate the factor-level feature impact of items in a session

此外,在会话推荐中,项目属性信息(如价格等)的影响同样不可小觑。依然以图1为例,在用户选择了华为手机的情况下,可以发现用户在两部华为手机中选择购买最贵(价格属性因素)的,表明用户购买手机时愿意付出更昂贵的代价,这些现象也被许多会话推荐模型所忽略。

为了解决单一会话建模数据稀疏、信息片面以及传统的项目嵌入表示学习无法准确表示用户多方面兴趣问题,本文提出基于因子级特征与属性偏好联合学习的会话推荐模型(Factor-level Feature and Attribute Preference Joint Learning Based Session Recommendation, FLAP-SR)。模型不仅考虑了本地会话内项目之间的依赖关系和全局级会话之间的共性依赖,而且将项目以下级别更细粒度的因子级特征依赖和项目属性因素也纳入了兴趣偏好学习范围。

本文主要工作如下:

(1) 为挖掘不同会话中项目共性依赖,构建全局项目依赖感知图,抽取不同会话中的项目转换模式,

有效缓解了单一会话因序列较短引起的数据稀疏和泛化不足的问题。

(2) 应用解纠缠表示学习,将项目嵌入解耦为多个不同因子级特征,获得用户不同因子级兴趣偏好,同时,将项目属性信息(如价格)也纳入学习任务范围,学习用户因子级兴趣偏好和属性偏好,完成对用户兴趣更细粒度、更全面的刻画。

(3) 在2个公开数据集上进行实验,本文模型在与基线模型的对比中取得较为优越的性能,证明本文模型的有效性。

1 相关工作

1.1 基于规则的会话推荐

根据项目被捆绑购买的现象,基于关联规则的方法^[6]认为捆绑购买的项目之间具备某种相似性,在学习项目关联规则基础上,计算与当前项目关联项目并推荐给用户。由于该类方法忽略了时间因素,只能建模用户静态兴趣,无法准确捕获用户近期动态

兴趣,且单一项目关联规则无法覆盖所有项目关联情况,因此不适用于复杂场景下的会话推荐。

基于序列模式的推荐旨在用户-交互序列上挖掘频繁模式进而指导后续推荐。该方法根据固定的规则捕捉项目转换模式,可能生成许多的冗余信息,增添时间复杂性且容易丢失其他重要模式。例如:FPMC(Factorizing Personalized Markov Chains)^[7]利用马尔科夫链生成转移矩阵并采用矩阵分解降低为每个用户建立矩阵的内存消耗;隐马尔科夫嵌入方法^[8]将推荐问题转化为求解欧几里得空间中的马尔科夫链正则化最大似然嵌入,计算转移概率。虽然这些基于马尔科夫假设的方法能捕获序列模式,同时也兼顾了用户潜在偏好,但由于其仅基于当前时间步情况预测未来,抛弃了过去的行为,独立性假设不符合现实,因此效果并不好。

1.2 基于图神经网络的会话推荐

深度神经网络因其强大的信息依赖捕获能力广泛应用于会话推荐并取得了很好的成效,如GRU (Gate Recurrent Unit)^[9]、ComiRec^[10]序列推荐框架。对于会话中可能出现重复购买的场景来说,序列推荐框架很难捕捉到这种来回反复转换的关系,因此,SR-GNN(Session-based Recommendation with Graph Neural Networks)^[11]首次将图神经网络应用于会话推荐,将会话序列建模为独立有向图,并利用邻接矩阵存储节点转换权重;CSRM(Collaborative Session-based Recommendation Machine)^[12]提出跨会话协同信息的重要性,以会话作为最小粒度单位,计算之前一定数量的会话信息对当前会话建模的重要性系数,但没有注意到过去会话的整体信息会给当前会话引入一些不可预知的噪声;HMSR(Hypergraph Convolutional Networks for Micro-behavior Session-based Recommendation)^[13]为了利用不同会话的信息,将不同会话构建为一个超图,以提取更细粒度的高阶特征,将不同会话的项目转换模式联系起来,但会话若有误点击项目,无疑会给超图引入许多不相关的信息,这种噪声会降低推荐的效果;也有一些工作将对比学习的思想^[14-15]引入图神经网络,挖掘语义空间中潜在邻居关系,然而对于稀疏场景,可能会导致学习到的负样本与用户兴趣不匹配,从而影响推荐效果,无法缓解会话推荐中天然存在的数据稀疏问题。

2 预备知识

本节将描述本文提出的FLAP-SR模型用到的前置知识和相关细节。

2.1 解纠缠特征因子表示

解纠缠表示学习(Disentangled Representation Learning, DRL)是一种可以将数据背后有意义的潜在因素解离出来的技术^[16]。本文应用DRL学习会话中项目背后的因子级兴趣表示,将项目原始嵌入分割成多个独立的因子维度,挖掘多因子级的细粒度语义。DRL输入是项目的原始嵌入,形式上,给定一个会话 $s_i = \{v_1, v_2, v_3, \dots, v_n\}$, 假设第 i 个项目的初始嵌入向量为 $\mathbf{e}_i \in \mathbb{R}^d$, 通过式(1)将其转换到不同语义空间以得到多个因子级嵌入。

$$\mathbf{c}_{i,k} = \sigma(\mathbf{w}_k^T \cdot \mathbf{e}_i) + \mathbf{b}^k, (1 \leq k \leq K) \quad (1)$$

式中: k 为项目第 k 个因子级特征, $\mathbf{w}_k \in \mathbb{R}^d$ 为可学习的训练参数, $\mathbf{b}^k$ 为偏置变量, σ 为激活函数。针对这些不同空间上的因子级特征,利用式(2)中距离相关法进行解耦,让因子相互独立。

$$\mathcal{L}_d = \sum_{k=1}^K \sum_{t \neq k}^K \text{dCor}(\mathbf{c}_{i,k}, \mathbf{c}_{i,t}) \quad (2)$$

式中: $\text{dCor}(\cdot)$ 是距离相关系数公式,用于衡量不同因子级特征的非线性相关程度,特别地, $\text{dCor}(X, Y)$ 为 0 时说明 X 与 Y 相互独立,其具体展开式如式(3)所示。

$$\text{dCor}(X, Y) = \frac{\text{dCov}(X, Y)}{\sqrt{\text{dVar}(X) \cdot \text{dVar}(Y)}} \quad (3)$$

式中: $\text{dCov}(X, Y)$ 表示变量 X 与 Y 之间的距离协方差, $\text{dVar}(X)$ 则表示自身的距离方差,详细推导在文献^[17]可找到。

2.2 全局项目依赖感知图

图2是会话集合构建全局级项目依赖无向图的过程。设有4个不同的会话,红色虚线为不同会话中滑动窗口(窗口大小为2,意味着捕获一阶转换)进行滑动捕获不同会话中同一项目转换。为了量化项目间转换的重要性,同时为避免误点击项目被引入会




图2 全局项目依赖感知图构建

Fig.2 Construction of global item-dependency awareness graph

话,需为图中每个节点的邻接边定义一个权重。本文直接将边出现的次数作为权重系数,得到图2中下方的全局级项目依赖感知图。

2.3 项目属性(价格)转换图

项目(商品)价格显著影响消费者的购买意愿,消费者往往在兴趣和价格之间反复权衡后作出决断,一些研究工作证明了将价格作为推荐模型的辅助信息能够更好地推断用户意图^[18-19]。推荐模型引入价格等属性信息时需先考虑其量化表示。价格是连续值,且不同项目价格区间跨度相差很大,因此,需要对价格值进行离散化和归一化,把用户购买不同项目的价格转换为用户对不同项目的价格水平偏好。例如,对鼠标而言,价格500元已是顶级价格了;但对手机而言,价格500元却很低。离散化和归一化后的价格水平将划分为 L 个(例如 L 为5)等级,每一个等级有自己的One-hot编码并可形成相应的嵌入。

文献[20]揭示了同一类别项目的价格服从logistic分布,且其概率密度函数如图3所示。利用式(4)可统计每个项目的绝对价格在其所属类别价格分布中所处的价格等级,以便跨类别统一项目价格量纲。




图3 同类商品价格分布

Fig.3 Price distribution of similar products

$$\text{Level} = \left\lfloor \frac{F(x_p) - F(\min)}{F(\max) - F(\min)} \times L \right\rfloor \quad (4)$$

式中: L 是价格水平最大等级; $F(x)$ 为逻辑斯谛回归的累积分布函数,式(5)为其展开式, μ 是该分布的数学期望, σ 为该分布的标准差。

$$F(x) = P(X \leq x) = \frac{1}{1 + e^{-\pi \frac{x-\mu}{\sqrt{3}\sigma}}} \quad (5)$$

3 模型总体框架

本文提出的FLAP-SR模型框架如图4所示,分为

3个模块:第一个模块为全局偏好学习模块,构建项目全局依赖感知图,挖掘用户多维度兴趣偏好,提高泛化性能;第二个模块因子级偏好学习模块,应用解纠缠表示学习获取用户行为的潜在兴趣因子;第三个模块属性(价格)偏好学习模块。第一个模块的输出先与第二个模块进行融合,共同学习因子级兴趣偏好,前两个模块的输出再与第三个模块进行多通道融合,共同完成推荐过程。

3.1 全局偏好学习

为克服会话序列较短时用户兴趣无法泛化的问题,构建全局项目依赖感知图,使用全局会话信息辅助模型学习用户潜在兴趣。在全局项目依赖感知图 $G_g = (V_g, E_g)$ 中,意图节点 $v_i^s \in V_g$ 对应的嵌入表示为 $\mathbf{h}_{v_i} \in \mathbb{R}^d$ 。利用会话感知注意力区分图中各邻居节点对意图节点 v_i^s 的影响程度。

$$\mathbf{h}_{\mathcal{N}_{v_i}^s} = \sum_{v_j \in \mathcal{N}_{v_i}^s} \pi(v_i^s, v_j^s) \mathbf{h}_{v_j} \quad (6)$$

式中: $\mathcal{N}_{v_i}^s$ 指的是在全局依赖感知图 G_g 中的邻居节点,这里的 π 用于评估节点 v_i^s 的邻居对其影响程度,直观上来看,与当前本地会话的偏好相近的项目更可能是用户的潜在感兴趣项目, π 的计算方式如式(7)和式(8)所示。

$$\pi(v_i^s, v_j^s) = \mathbf{q}_i^T \sigma \left(\mathbf{w}_1 \left[\left(\frac{1}{n} \sum_{v_j \in S} \mathbf{h}_{v_j} \odot \mathbf{h}_{v_j} \right) \right] \mathbf{w}_{ij}^s \right) \quad (7)$$

$$\pi(v_i^s, v_j^s) = \frac{\exp(\pi(v_i, v_j))}{\sum_{v_k \in \mathcal{N}_{v_i}^s} \exp(\pi(v_i, v_k))} \quad (8)$$

式中: $\mathbf{W}, \mathbf{q}$ 均为可训练参数; w_{ij}^s 为实数,即全局项目依赖感知图 G_g 上连接节点 v_i^s 和 v_j^s 的权重; $\odot$ 为哈达玛积。最后利用式(9)~(10)聚合全局项目依赖感知图上 L 跳的邻居节点信息,以更好地表示节点 v_i^s 。

$$\mathbf{h}_v^g = \text{ReLu}(\mathbf{W}_2[\mathbf{h}_v \parallel \mathbf{h}_{\mathcal{N}_v^g}]) \quad (9)$$

$$\mathbf{h}_v^{g,l} = \text{agg}(\mathbf{h}_v^{(l-1)}, \mathbf{h}_{\mathcal{N}_v^g}^{(l-1)}) \quad (10)$$

3.2 因子级偏好学习

针对一个本地会话 $s = \{v_1, v_2, v_3, v_4, v_2, v_1\}$ 的第 i 个项目,通过DRL层后得到 K 个不同因子级项目特征 $\mathbf{C}_i = \{\mathbf{c}_{i,1}, \mathbf{c}_{i,2}, \mathbf{c}_{i,3}, \dots, \mathbf{c}_{i,K}\}$,正如图4的网络模块所示,根据会话中项目的不同因子级特征逐个构建本地会话图 $G_s^{(k)} = (V_s^k, E_s^k)$,并分别输入到门控图神经网络(Gated Graph Neural Network, GGNN)进行学习。在每个因子级本地会话图中,边集 E_s^k 中的一条边连接着2个项目,为了在不同因子维度上特异化图结构,将




图4 FLAP-SR模型框架

Fig.4 Framework of FLAP-SR model

两项目之间的归一化相似度 $w_{i,j}^k$ 作为本地会话图的邻接矩阵权重,如式(11)所示。

$$w_{i,j}^k = \frac{\mathbf{c}_{i,k} \cdot \mathbf{c}_{j,k}}{\sum_{j' \in \mathcal{N}_i} \mathbf{c}_{i,k} \cdot \mathbf{c}_{j',k}} \quad (11)$$

式中: $\mathcal{N}_i$ 表示节点 i 在第 k 级会话图上的所有一阶邻居节点。由于本地会话图是有向图,其邻接矩阵 $\mathbf{A}_{s,k}$ 由其出度矩阵 $\mathbf{A}_{s,k}^{(\text{out})}$ 和入度矩阵 $\mathbf{A}_{s,k}^{(\text{in})}$ 两部分组成,图5展示了本地会话 s 的第 k 因子级会话图的邻接矩阵示例。




图5 图邻接矩阵

Fig.5 Construction of Session-based Graph

在 k 个因子级会话图上执行信息传播算法,即针对图 $G_s^{(k)}$ 节点嵌入 $\mathbf{c}_{i,k}$ 使用式(12)提取其邻域节点的信息并进行信息传播。

$$\mathbf{c}_{i,k}^l = \text{GGNN}(\mathbf{c}_{i,k}^{l-1}, \mathbf{A}_{s,k}^{(\text{in})}, \mathbf{A}_{s,k}^{(\text{out})}) \quad (12)$$

式中: $\mathbf{c}_{i,k}^{l-1} \in \mathbb{R}^d$ 是在GGNN的 $l-1$ 层(1/L)第 i 个项目节

点的嵌入向量,由此节点的高阶信息不断地传播并聚合,从而获得最后的节点向量 $\mathbf{c}_{i,k}^L$ 。

3.3 属性(价格)偏好学习

根据2.3节所介绍的价格等级建模方式,获得一个价格转换序列,并以此构建价格转换图,将价格等级编码转换为对应的初始嵌入 $\mathbf{h}_{v_i}^p \in \mathbb{R}^d$,进而获得各个价格节点的潜在表示 $\mathbf{H}_p = \{\mathbf{h}_{v_1}^p, \mathbf{h}_{v_2}^p, \dots, \mathbf{h}_{v_n}^p\}$,进一步地,在GGNN基础上再使用多头自注意力^[21]对用户价格偏好 $\mathbf{P}_u$ 建模。

$$\text{head}_i = \text{MultiHeadAttention}(\mathbf{H}_p, \mathbf{W}_i^Q, \mathbf{W}_i^K, \mathbf{W}_i^V) \quad (13)$$

$$\mathbf{F}_p = [\text{head}_1, \text{head}_2, \dots, \text{head}_h] \quad (14)$$

式中: $\mathbf{W}_i^Q, \mathbf{W}_i^K$ 和 $\mathbf{W}_i^V \in \mathbb{R}^{\frac{d}{h} \times d}$ 是投影矩阵, h 是头的个数,最后通过拼接各个子空间的嵌入得到各价格节点所代表的偏好 $\mathbf{F}_p \in \mathbb{R}^{d \times n}$,进而获得用户价格偏好 $\mathbf{P}_u \in \mathbb{R}^d$ 。

$$\mathbf{P}_u = \mathbf{F}_p^{(n)} \quad (15)$$

3.4 多通道偏好融合推荐

介绍完3个重要学习模块后,下面开始对用户的意图进行融合表示。在因子级偏好学习模块中,针对项目的不同因子级嵌入使用sumpooling方式融合 $\mathbf{c}_{i,k}^L$ 与 $\mathbf{h}_{v_i}^{s,L}$,获得最终的因子级嵌入向量。

$$\mathbf{c}_{i,k}^* = \mathbf{c}_{i,k}^L + \mathbf{h}_{v_i}^{g,L} \quad (16)$$

式中: $\mathbf{c}_{i,k}^*$ 为融合了用户潜在兴趣的最终因子级项目嵌入表示。随后将 $\mathbf{c}_{i,k}^*$ 输入到式(17)~(19)所示的会话编码器, 得到 K 个因子级兴趣偏好表示, 其中会话编码器考虑到用户兴趣偏好会随时间变化而转移, 因此使用反向位置嵌入 $\text{pos}_i \in \mathbb{R}^d$ 用以捕获用户的动态兴趣偏好^[22]。

$$\mathbf{f}_{i,k}^* = \tanh(\mathbf{W}_3[\mathbf{c}_{i,k}^*; \text{pos}_i] + \mathbf{b}) \quad (17)$$

$$\boldsymbol{\beta}_i = \mathbf{q}_2^\top \sigma(\mathbf{W}_4 \mathbf{f}_{i,k}^* + \mathbf{W}_5 \overline{\mathbf{f}_k} + \mathbf{b}) \quad (18)$$

$$\mathbf{I}_u^k = \sum_{i=1}^n \boldsymbol{\beta}_i \mathbf{f}_{i,k}^* \quad (19)$$

各个因子级兴趣偏好均可能影响用户的价格偏好, 而价格偏好亦可突出相关性较高的因子级兴趣偏好, 即项目哪个因素值得用户违背自己的消费习惯和消费水平。受自然语言处理中上下文注意力机制的启发^[23], 计算各因子级兴趣偏好 $\mathbf{I}_u^k$ 对价格偏好 $\mathbf{P}_u$ 的影响程度 η_k 。直观地看, η_k 越高说明第 k 因子级兴趣偏好对用户作出决策影响越大。

$$\eta_k = \frac{\mathbf{P}_u^\top \mathbf{I}_u^k}{\sqrt{d}} \quad (20)$$

最后针对会话的每个因子级兴趣偏好加权求和, 得到初步的用户意图表示, 又考虑到价格和兴趣偏好是相互驱动的, 故添加一层非线性变换令两者更为紧密地联合学习, 得到总体的兴趣表示 $\mathbf{I}^*$ 。同样地, 对价格偏好也施加兴趣表示的影响, 以丰富其语义, 加深两者的关联度更利于意图建模, 如式(21)~(22)所示。

$$\mathbf{I}^* = \tanh(\mathbf{W}_1^* (\sum_{k=1}^K \eta_k \mathbf{I}_u^k) + \mathbf{W}_2^* \mathbf{P}_u + \mathbf{b}_1^*) \quad (21)$$

$$\mathbf{P}^* = \tanh(\mathbf{W}_3^* (\mathbf{P}_u \odot \mathbf{I}^*) + \mathbf{b}_2^*) \quad (22)$$

$$\mathbf{M}^* = \tanh(\mathbf{W}^p(r_{\text{balance}} \odot \mathbf{P}^*) + \mathbf{W}^l((1 - r_{\text{balance}}) \odot \mathbf{I}^*)) \quad (23)$$

式(23)是融合用户最终意图的过程, 正如前文所述, 用户往往在价格偏好与兴趣偏好之间反复权衡, 故将超参数 r_{balance} 作为一个权衡系数加入融合过程, 至此实现了多通道偏好相互驱动并融合的过程, $\mathbf{M}^*$ 是语义之间彼此丰富后形成的最终用户意图, 进而计算下一个被点击项目的概率 $\hat{y}_i$ 。

$$\hat{y}_i = \text{softmax}(\mathbf{M}^{*T} \mathbf{e}_i) \quad (24)$$

本文使用的损失函数由两部分构成, 定义如下:

$$\mathcal{L}(\hat{\mathbf{y}}) = - \sum_{i=1}^m y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i) \quad (25)$$

$$\mathcal{L}_{\text{sum}} = \mathcal{L}(\hat{\mathbf{y}}) + \lambda \mathcal{L}_d \quad (26)$$

式中: $\mathcal{L}(\hat{\mathbf{y}})$ 是交叉熵损失函数, $y_i \in Y$ 是真实标签, 而 $\mathcal{L}_d$ 是式(2)所介绍的解纠缠损失, 其中 λ 是控制解纠缠学习正则化损失的超参数。

4 实验与分析

本节首先介绍实验部分用到的数据集, 要对比的基线方法以及评价指标, 再从以下5个方面探究本文所提出模型的性能:

问题1: FLAP-SR模型整体推荐效果如何, 对比会话推荐领域已有的方法有何优势?

问题2: FLAP-SR中因子级特征和属性(价格)偏好对意图表达是否具有重要影响?

问题3: 跨会话全局信息是否有效?

问题4: FLAP-SR中因子个数 K 是否合理?

问题5: 属性(价格)和兴趣之间的权衡是否有必要?

4.1 数据集

本文实验采用2个公开数据集。

Cosmetics: 数据科学竞赛平台kaggle的公开数据集, 其记录了某个化妆品专卖电商平台上自2019年10月~2020年2月的用户行为日志。文件中的每一条记录都代表一个用户-项目交互事件, 记录了用户和项目之间的多对多关系。本文使用其中一个月的记录, 仅保留会话中交互类型为加购物车和购买类型的记录。

Diginetica: 来自于CIKM Cup 2016所发布的一个电子商务数据集, 其数据由多种类型的数据组成, 被广泛地用于会话推荐。本文采用其中的交易数据验证本文模型的性能。

借鉴文献[13]和[15]中对会话序列的预处理方式, 在2个数据集中分别过滤掉出现次数少于10次的项目, 且对于会话集中的所有会话, 需要剔除长度为1的会话。在2个数据集中, 都保留最后一周的会话作为测试集, 预处理后的数据统计如表1所示。

4.2 评价指标

使用基于排名的 $P@K$ 和 $MRR@K$ 两种评价指标来衡量本文所提出模型的推荐效果。考虑到现实生活中接触到的各类应用的情况, 选取 K 为20。

$P@K$: 该分数用于衡量模型预测的精确度, 计算推荐的前 K 个项目中正确项目所占测试集会话样本总数的比例:

$$P@K = \frac{n_{\text{hit}}}{N} \quad (27)$$

MRR@K: 该分数用于衡量推荐项目的排名顺序,即反映推荐的项目是否处于序列的前列,更强调位置关系:

$$\text{MRR@K} = \frac{1}{N} \sum_{v_{\text{target}} \in S_{\text{test}}} \frac{1}{\text{rank}(v_{\text{target}})} \quad (28)$$

式中: N 为测试集中的会话样本数, $\text{rank}(v_{\text{target}})$ 为在测试集会话样本中正确项目在推荐列表的排名。

4.3 对比方法

为了突出本模型在推荐性能方面的优越性,将其与以下算法作对比:

S-POP: 将会话中出现最频繁的项目用作推荐。

SKNN: 将会话作为整体,推荐与目标会话相似的会话中的项目作为推荐结果。

GRU4Rec^[9]: 基于循环神经网络模型,使用GRU来对会话中的项目进行序列建模的方法。

NARM^[4]: 在GRU4Rec的基础之上添加了注意力机制以更好地关注长短期兴趣。

SR-GNN^[11]: 将本地会话构建为会话图后使用图神经网络捕获项目-项目之间的复杂转换关系。

GCE-GNN^[22]: 将全局会话信息建模为全局图学习项目信息,并融合会话图提取的用户兴趣学习两个层次的项目表示。

COTREC^[15]: 是DHCHN的变体,利用会话间图和会话内图协同训练挖掘自监督信号,增强模型的推荐效果。

S²-DHCHN^[24]: 通过将会话序列构建为超图和线图,经超图卷积神经网络学习后采用自监督学习的方式增强项目表示。

STOSA^[25]: 引入一种随机自注意力以捕获序列推荐中的协同传递性,并通过考虑用户行为中的基本兴趣和兴趣可变性,获得更精准的用户兴趣表征。

FLAP-SR/IEG: 将全局项目依赖感知图输出的内容从FLAP-SR模型中去除,其他模块与FLAP-SR无异。

FLAP-SR/DRL: 针对本地会话图去除因子级特征,仅用单通道GGNN表示项目嵌入,损失函数亦只包含交叉熵损失。

FLAP-SR/PP: 去除属性(价格)偏好模块,只将每个因子级兴趣偏好相加作为总体会话兴趣。

4.4 参数设置

为了在各对比模型之间进行公平比较,本模型与各基线均采用相同的嵌入维度。并且,本模型中涉及到的嵌入矩阵和训练参数都以均值为0、标准差为0.1的高斯分布作初始化。兴趣偏好模块中的因子个数 K 在两个数据集中分别设为5和8,并将多通道融合过程中的权衡系数 r_{balance} 设置为0.4和0.8,原因将在4.7和4.8节说明。将价格偏好模块的多头自注意力机制头数设置为4。由于图神经网络层数过深会造成过平滑的结果,故本文中GGNN层数设为3。此外使用Adam优化器,设置优化器初始学习率为0.01,使用每3个训练周期衰减0.1的学习率衰减策略,L2正则化系数设为 10^{-5} ,并将批处理大小设为128,以及控制参数 λ 设为5。

4.5 结果分析(问题1)

首先分析FLAP-SR模型的整体性能,其与基线模型的对比结果见表2,可以看出GRU4Rec的性能最差,这是因为基于循环神经网络的序列建模一般对于捕获长序列信息具有较好的效果,但是从表1中的数据集中平均会话长度来看,会话序列普遍较短,且会话场景下项目-项目转换关系存在短期内反复转换的复杂情况,这是造成效果收益差的主要原因。NARM和STOSA模型利用更先进的注意机制,更加关注对用户来说比较重要的项目以捕获用户在会话中的主要兴趣,取得明显提升。

SKNN的结果表明会话之间的有效协同信息有助于挖掘用户潜在偏好。类似地,基于图网络模型的推荐方法(SR-GNN、GCE-GNN、COTREC、S²-DHCHN)将会话序列建模为图结构,由于其擅长捕捉项目之间成对转移关系,所以适合会话推荐场景下的兴趣偏好建模。但相比于SR-GNN方法而言,考虑了全局会话协同信息的GCE-GNN和COTREC等表现出更令人满意的效果。

然而以上算法基本只考虑了项目本身作为一个整体的表示信息,忽略了隐藏在项目背后的潜在因子对用户会话兴趣的影响,而且都没有将项目明确的上下文属性信息(如价格和类别)纳入学习网络,因此其性能都差于本文所提出的FLAP-SR模型。从表2可以发现,FLAP-SR在Diginetica数据集上比最好

表1 数据集统计信息
Table 1 Dataset statistics

数据集	会话个数	物品个数	价格等级	点击数	物品类别	平均会话长度	因子数
Cosmetics	156 922	23 194	10	1 058 263	301	6.74	8
Diginetica	187 540	24 889	100	855 070	721	4.56	5

的基线模型在P@20指标上高出1.92,在MRR@20指标上高2.15。而在Cosmetics数据集上,比表现最好的基线模型在P@20和MRR@20指标上分别高2.76和1.13。进一步说明了FLAP-SR模型考虑多因子级兴趣偏好与价格偏好驱动互补的方式能够有效提高推荐性能。

4.6 消融实验(问题2、3)

由表2可以知道FLAP-SR模型的整体性能优于现有的大多数方法,为探究FLAP-SR各组件对整体性能提升的贡献程度,并回答问题2和3,下面将设置3个变体模型进行对照实验,具体结构已在4.3节作了说明,其结果见表3。

可以看出FLAP-SR的各个组件对整体性能的提升效果不尽相同:影响最大的是FLAP-SR/DRL,对比FLAP-SR在Diginetica数据集中的表现,其性能指标P@10和MRR@10分别下降了0.91和0.87,P@20与MRR@20则下降了1.61和1.05,可见去除解纠缠表示层后,原始嵌入将以单通道的形式输入图神经网络,进而输出的也是单一维度的会话偏好,效果差强人意。其呼应了图1中的会话示例,即忽视项目的潜在上下文分析将损害推荐性能,而通过DRL层分解原始嵌入至多个独立维度,并在各个维度上学习用户的会话兴趣(因子级兴趣)对最终意图的增强效果是显而易见的,同时也说明了隐藏在项目背后的多个相对独立的潜在因子特征更能丰富项目表示。其次,通过FLAP-SR/PP在Diginetica数据集中的结果可以

发现,其对比于FLAP-SR的性能指标,P@10和MRR@10分别下降了0.72、0.49,而P@20和MRR@20则分别下降了1.16、0.83,造成此种性能损失的主要原因是去除了属性(价格)偏好模块后,各个因子级兴趣将直接通过sumpooling方式形成用户最终意图表示,即假设各个因子级兴趣的重要程度是一样的,模型失去了“个性化”的首要目标。这是不合理的,因为不同用户对项目的属性都有不同的偏爱,如品牌、价格、生产地,结果证明了FLAP-SR选取的价格偏好模块对用户的兴趣偏好建模有促进和驱动的作用,可以区别用户更为关注的某方面兴趣,用户甚至宁愿为这方面的因素而改变自身的消费习惯。另外结合FLAP/DRL和FLAP/PP的结果可见因子级兴趣和价格偏好相辅相成,对模型整体性能的提升作出了巨大贡献,说明多因子级兴趣偏好在融合上下文属性信息后表达的用户意图更为恰当。最后,全局项目依赖感知图将会话集中的所有项目转换模式作为一个令用户跳出信息茧房的辅助信息(具体见2.2),其通过挖掘与当前会话具有相似行为的其他用户的交互项目进而作为当前会话的潜在兴趣,从FLAP-SR/IEG在Diginetica和Cosmetics数据集上的结果可以发现虽然其对推荐性能的提升不如前两者,但可能因为会话项目的因子级特征占主导从而更能与价格偏好相融合。即使如此,亦不能忽略全局项目依赖感知图相比于其他方法对用户兴趣的弱泛化性起到的缓解作用。

表2 对比实验结果
Table 2 Comparison of experimental results

模型	Diginetica				Cosmetics			
	P@10	MRR@10	P@20	MRR@20	P@10	MRR@10	P@20	MRR@20
S-POP	25.51	18.82	25.91	19.84	32.83	26.63	38.43	27.32
SKNN	45.68	20.24	55.76	21.10	40.22	30.40	47.63	30.80
GRU4Rec	22.04	11.32	27.88	11.73	19.41	14.43	21.80	14.60
NARM	46.56	21.76	57.34	23.27	42.63	34.17	46.29	34.52
SR-GNN	45.74	21.32	56.80	22.87	44.11	34.59	48.01	34.96
GCE-GNN	47.07	21.85	58.93	23.42	44.72	35.11	48.82	35.30
COTREC	48.14	22.07	61.82	23.75	45.11	34.83	50.12	35.24
S ² -DHCN	45.89	21.08	54.91	22.03	40.48	32.86	47.95	33.13
STOSA	46.37	20.96	58.70	23.41	43.70	34.67	48.77	35.18
FLAP-SR	49.83	22.65	63.74	25.90	46.91	35.50	52.88	36.43


表3 消融实验结果
Table 3 Experimental results of ablation

模型	Diginetica				Cosmetics			
	P@10	MRR@10	P@20	MRR@20	P@10	MRR@10	P@20	MRR@20
FLAP-SR/IEG	49.57	22.45	63.28	25.66	46.47	35.23	51.95	36.04
FLAP-SR/DRL	48.92	21.78	62.13	24.85	45.08	34.82	51.41	35.77
FLAP-SR/PP	49.11	22.16	62.58	25.07	45.97	35.07	52.16	35.90
FLAP-SR	49.83	22.65	63.74	25.90	46.91	35.50	52.88	36.43


4.7 因子个数 K 的影响(问题4)

以上实验中,除FLAP-SR/DRL外的结果都是在因子个数 K 为最佳数值下得到的,下面将探究兴趣偏好模块因子 K 的大小对模型整体性能的影响。

依据图6中的性能变化趋势,可以明确知道因子个数 K 对挖掘用户会话的兴趣偏好具有较大的影响,在因子个数仅为1时相当于退化成FLAP-SR/DRL模型,随着因子个数的增加,模型性能也逐渐提升,不同因子级兴趣偏好对模型起到了良好的引导作用。在Digintica数据集中, K 为5时模型达到最佳性能,随后开始下降,这表明分解的因子个数过多会对模型的性能造成干扰,损害推荐效果,Comestic数据集上的指标变化亦再次说明了以上分析的普遍性。2个数据集的最佳 K 值不尽相同,说明在不同的场景下,用户意图会被各种不同的因素所影响。



(a) 因子个数 K 对MRR@20指标的影响



(b) 因子个数 K 对P@20指标的影响

图6 因子个数对模型性能的探究

Fig.6 The effect of number of factors on model performance

4.8 权衡系数影响(问题5)

用户在各类型的消费场景中,兴趣和价格一直都是被权衡的2个维度,有的经常因为价格昂贵而不得不放弃喜欢的商品,也有的因为强烈的兴趣而愿意付出昂贵的价格,因此权衡 $r_{balance}$ 对模型的效果有着重要的影响。为研究在两个数据集中用户对价格和兴趣的敏感程度,将 $r_{balance}$ 取0到1的小数进行实验,得到的结果如图7所示。




图7 权衡系数对模型准确率的影响

Fig.7 The effect of balance term on model precision

可见在不同的数据集上,权衡系数对模型的精度都有着一定程度的影响,在Digintica数据集中权衡系数为0.4时效果最好,随着系数的增大,模型效果下降显著,说明数据源的网站中的用户购买行为是以兴趣为主导。而在Cosmetics中,权衡系数为0.8时的效果最好,可能的原因是该数据集采集自化妆品专卖平台,以美妆护肤产品为主,价格方差较大,用户消费水平的区分度也较高,因此造成用户对价格敏感度较大。以上充分说明在不同的场景下,对兴趣偏好和属性(价格)的权衡是有必要的,其在不同程度上影响着模型的性能。

5 结语

会话推荐在当今信息时代具有重要研究意义,基于图神经网络的会话推荐方法更是当前的研究热点。针对已有研究工作存在的不足,本文提出了因子级特征与属性偏好联合学习模型,不仅考虑了全局会话的全局依赖信息,而且更进一步捕获项目价格、类别等上下文属性与隐藏在项目背后的潜在因子之间的交互信息。方法中提取的因子级兴趣偏好充分考虑了用户意图的多方面因素,结合价格偏好,通过注意力网络很好地衡量了各因子级偏好对用户意图的贡献度,使推荐更为精确。在未来的研究工作中,可以考虑通过构建超图,将更多的上下文属性信息纳入到学习中,在复杂会话环境下挖掘更高层次的项目及其属性信息,学习更深层次的因子兴趣信息,从而达到提升推荐效果的目的。

参考文献:

- [1] HE Z, LIU W, GUO W, *et al.* A survey on user behavior modeling in recommender systems[C]//International Joint Conference on Artificial Intelligence. Macao: IJCAI, 2023: 6656-6664.

- [2] YAP G E, LI X L, YU P S. Effective next-items recommendation via personalized sequential pattern mining[C]// Database Systems for Advanced Applications. Busan: Springer Berlin Heidelberg, 2012: 48-64.
- [3] LUDEWIG M, JANNACH D. Evaluation of session-based recommendation algorithms [J]. User Modeling and User-Adapted Interaction, 2018, 28(4): 331-390.
- [4] LI J, REN P, CHEN Z, *et al.* Neural attentive session-based recommendation[C]//ACM on Conference on Information and Knowledge Management. New York: Association for Computing Machinery, 2017: 1419-1428.
- [5] GAO C, ZHENG Y, LI N, *et al.* A survey of graph neural networks for recommender systems: challenges, methods and directions [J]. ACM Transactions on Recommender Systems, 2021, 1(3): 1-51.
- [6] 林穗, 郑志豪. 基于关联规则的客户行为建模与商品推荐研究[J]. 广东工业大学学报, 2018, 35(3): 90-94.
LIN S, ZHENG Z H. A research of a recommender system-based on customer behavior modeling by mining association rules [J]. Journal of Guangdong University of Technology, 2018, 35(3): 90-94.
- [7] RENDLE S, FREUDENTHALER C, SCHMIDT-THIEMEL. Factorizing personalized markov chains for next-basket recommendation[C]//World Wide Web Conference. New York: Association for Computing Machinery, 2010: 811-820
- [8] WU X, LIU Q, CHEN E, *et al.* Personalized next-song recommendation in online karaokes[C]//ACM Conference on Recommender Systems. New York: Association for Computing Machinery, 2013: 137-140.
- [9] HIDASI B, KARATZOGLOU A, BALTRUNAS L, *et al.* Session-based recommendations with recurrent neural networks[C]//International Conference on Learning Representations. San Juan: ICLR, 2016: 1-10.
- [10] CEN Y, ZHANG J, ZOU X, *et al.* Controllable multi-interest framework for recommendation[C]//ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: Association for Computing Machinery, 2020: 2942-2951.
- [11] WU S, TANG Y, ZHU Y, *et al.* Session-based recommendation with graph neural networks[C]//AAAI Conference on Artificial Intelligence. Honolulu: AAAI, 2019: 346-353.
- [12] WANG M, REN P, MEI L, *et al.* A collaborative session-based recommendation approach with parallel memory modules[C]//ACM SIGIR Conference on Research and Development in Information Retrieval. New York: Association for Computing Machinery, 2019: 345-354.
- [13] 杨显鹏, 李晓楠, 李冠宇. 基于超图卷积网络的用户微行为会话推荐[J]. 计算机工程与应用, 2023, 59(16): 108-114.
YANG X P, LI X N, LI G Y. Hypergraph convolutional networks for user micro-behavior session-based recommendation [J]. Computer Engineering and Applications., 2023, 59(16): 108-114.
- [14] LIN Z, TIAN C, HOU Y, *et al.* Improving graph collaborative filtering with neighborhood-enriched contrastive learning[C]//ACM Web Conference. New York: Association for Computing Machinery, 2022: 2320-2329.
- [15] XIA X, YIN H, YU J, *et al.* Self-supervised graph co-training for session-based recommendation[C]//ACM International Conference on Information & Knowledge Management. New York: Association for Computing Machinery, 2021: 2180-2190.
- [16] WANG X, JIN H, ZHANG A, *et al.* Disentangled graph collaborative filtering[C]//ACM SIGIR Conference on Research and Development in Information Retrieval. New York: Association for Computing Machinery, 2020: 1001-1010.
- [17] SZÉKELY G J, RIZZO M L, BAKIROV N K. Measuring and testing dependence by correlation of distances [J]. Annals of Statistics, 2007, 35(6): 2769-2794.
- [18] ZHENG Y, GAO C, HE X, *et al.* Price-aware recommendation with graph convolutional networks[C]//IEEE 36th International Conference on Data Engineering (ICDE). Online: IEEE, 2020: 133-144.
- [19] ZHANG X, XU B, YANG L, *et al.* Price does matter! modeling price and interest preferences in session-based recommendation[C]//ACM SIGIR Conference on Research and Development in Information Retrieval. New York: Association for Computing Machinery, 2022: 1684-1693.
- [20] GREENSTEIN-MESSICA A, ROKACH L. Personal price aware multi-seller recommender system: evidence from eBay [J]. Knowledge-Based Systems, 2018, 150: 14-26.
- [21] ANH P H, BACH N X, PHUONG T M. Session-based recommendation with self-attention[C]//International Symposium on Information and Communication Technology. New York: Association for Computing Machinery, 2019: 1-8.
- [22] WANG Z, WEI W, CONG G, *et al.* Global context enhanced graph neural networks for session-based recommendation[C]//ACM SIGIR Conference on Research and Development in Information Retrieval. New York: Association for Computing Machinery, 2020: 169-178.
- [23] LU Y, ZENG J, ZHANG J, *et al.* Attention calibration for transformer in neural machine translation[C]//Annual Meeting of the Association for Computational Linguistics. Online: Association for Computational Linguistics, 2021: 1288-1298.
- [24] XIA X, YIN H, YU J, *et al.* Self-supervised hypergraph convolutional networks for session-based recommendation[C]//AAAI Conference on Artificial Intelligence. Vancouver: AAAI, 2021, 35(5): 4503-4511.
- [25] FAN Z, LIU Z, WANG Y, *et al.* Sequential recommendation via stochastic self-attention[C]//Proceedings of the ACM Web Conference. New York: Association for Computing Machinery, 2022: 2036-2047.

(责任编辑: 张玮欣 英文审核: 熊荣斌)