



计算机科学

COMPUTER SCIENCE

基于用户长短期偏好的序列推荐模型

雒晓辉, 吴云, 王晨星, 余文婷

引用本文

雒晓辉, 吴云, 王晨星, 余文婷. [基于用户长短期偏好的序列推荐模型](#) [J]. 计算机科学, 2023, 50(4): 47-55.

LUO Xiaohui, WU Yun, WANG Chenxing, YU Wenting. [Sequential Recommendation Model Based on User's Long and Short Term Preference](#) [J]. Computer Science, 2023, 50(4): 47-55.

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)

[基于合成图像和Xception改进模型的安卓恶意家族分类方法](#)

Android Malware Family Classification Method Based on Synthetic Image and Xception Improved Model

计算机科学, 2023, 50(4): 351-358. <https://doi.org/10.11896/jsjcx.220300200>

[基于交互注意力和图卷积网络的方面级情感分析](#)

Aspect-level Sentiment Classification Based on Interactive Attention and Graph Convolutional Network

计算机科学, 2023, 50(4): 196-203. <https://doi.org/10.11896/jsjcx.220100105>

[基于多邻接图与多头注意力机制的短期交通流量预测](#)

Short-time Traffic Flow Forecasting Based on Multi-adjacent Graph and Multi-head Attention Mechanism

计算机科学, 2023, 50(4): 40-46. <https://doi.org/10.11896/jsjcx.220200079>

[传播树结构结点及路径双注意力谣言检测模型](#)

Dual-attention Network Model on Propagation Tree Structures for Rumor Detection

计算机科学, 2023, 50(4): 22-31. <https://doi.org/10.11896/jsjcx.220200037>

[文档增强型知识库问答](#)

Document-enhanced Question Answering over Knowledge-Bases

计算机科学, 2023, 50(3): 266-275. <https://doi.org/10.11896/jsjcx.220300022>

基于用户长短期偏好的序列推荐模型

雒晓辉^{1,2} 吴云^{1,2} 王晨星¹ 余文婷¹

1 贵州大学公共大数据国家重点实验室 贵阳 550025

2 贵州大学计算机科学与技术学院 贵阳 550025

(gs.xhluo20@gzu.edu.cn)

摘要 针对现有序列推荐模型忽略了不同用户的个性化行为,导致模型不能充分捕获用户动态偏好而产生的兴趣漂移等问题,提出了一种基于用户长短期偏好的序列推荐模型(Sequential Recommendation Model Based on User's Long and Short Term Preference, ULSP-SRM)。首先,根据用户的序列中交互物品的类别和时间信息生成用户的动态类别嵌入,进而有效建立物品之间的关联性,并且降低数据的稀疏性;其次,根据用户当前点击物品和最后一项点击的时间间隔信息生成个性化时序位置嵌入矩阵,模拟用户的个性化聚集现象,以更好地反映用户偏好的动态变化;然后,将融合了个性化时序位置嵌入矩阵的用户长期偏好序列以会话为单位输入门控循环单元中,生成用户的长期偏好表示,并通过注意力机制将用户长短期偏好进行融合,生成用户的最终偏好表示,从而达到充分捕获用户偏好的目的;最后,将用户最终偏好表示输入推荐预测层进行下一项推荐预测。在 Amazon 公开数据集的 7 个子集上进行实验,采用 AUC(Area Under Curve)值、召回率和精确率指标进行综合评估,实验结果表明,所提模型的表现优于其他先进基准模型,有效地提升了推荐性能。

关键词: 序列推荐;长短期偏好;个性化时序位置;兴趣漂移;注意力机制

中图分类号 TP311

Sequential Recommendation Model Based on User's Long and Short Term Preference

LUO Xiaohui^{1,2}, WU Yun^{1,2}, WANG Chenxing¹ and YU Wenting¹

1 State Key Laboratory of Public Big Data, Guizhou University, Guiyang 550025, China

2 College of Computer Science and Technology, Guizhou University, Guiyang 550025, China

Abstract Aiming at the problem that the existing sequence recommendation model ignores the personalized behavior of different users, the model cannot fully capture the interest drift caused by users' dynamic preferences, a sequence recommendation model based on users' long and short term preferences(ULSP-SRM) is proposed. Firstly, the dynamic category embedding of the user is generated according to the category and time information of the interactive items in the user's sequence, thereby effectively establishing the correlation between the items and reducing the sparsity of the data. Secondly, according to the time interval information of the user's current clicked item and the last clicked item, a personalized time series position embedding matrix is generated to simulate the user's personalized aggregation phenomenon and better reflect the dynamic change of user preference. Then, the user's long-term preference sequence fused with the personalized time-series position embedding matrix is input into the gated recurrent unit in units of sessions to generate the user's long-term preference representation, and the user's long and short term preferences are fused through the attention mechanism to generate the final preference representation of the user, to achieve the purpose of fully capturing the user's preference. Finally, the final user preference representation is input to the recommendation prediction layer for the next recommendation prediction. Experiments are carried out on seven subsets of Amazon public data set, and the area under curve(AUC), recall rate and precision rate indicators are used for comprehensive evaluation. Experimental results show that the proposed model outperforms other advanced benchmark models, effectively improving recommended performance.

Keywords Sequence recommendation, Long and short term preference, Personalized time series location, Interest in the drift, Attention mechanism

到稿日期:2022-01-27 返修日期:2022-06-22

基金项目:黔科合基础(ZK[2022]119);国家自然科学基金(61662009)

This work was supported by the Science and Technology Foundation of Guizhou Province(ZK[2022]119) and National Natural Science Foundation of China(61662009).

通信作者:吴云(wuyun_v@126.com)

1 引言

序列推荐系统 (Sequential Recommendation System, SRS) 已经成为推荐领域的热门研究内容。序列推荐模型主要通过构建用户-物品之间的交互来为用户推荐其可能感兴趣的物品。在传统包括基于内容和协同过滤的推荐模型中^[2], 通常以静态的方式建模用户-物品交互, 只能捕获用户的静态偏好。事实上, 用户-物品交互本质上是具有时间顺序依赖性的, 用户偏好可能会随着时间的推移而改变。SRS 将用户-物品交互视为一个动态序列, 并考虑到顺序依赖关系, 以捕获用户长期偏好和短期兴趣来更准确地进行推荐^[3]。然而, 现有的大多数推荐方法如基于用户的协同过滤算法^[4]都是隐式地将用户进行分组, 它们不能明确地对物品类别之间的相关性进行建模。此外, 不同用户在相同时间段的习惯不一定相同, 例如有的用户喜欢在双十一等购物节采购, 有的用户则习惯错峰购买, 我们将这种现象称作“个性化时序位置聚合”, 针对这些用户的推荐机制显然是不同的。

近年来, 学者们采用用户的长期偏好和短期兴趣相结合来提升推荐效果^[5]。然而, 现有研究通常以静态方式构建用户的兴趣偏好, 往往忽略了用户兴趣偏好是动态变化的问题。另外, 随着时间的推移, 用户的兴趣偏好在不断地发生变化, 现有研究不能充分捕获用户的兴趣, 产生兴趣漂移的问题。

因此, 为了解决以上问题, 充分捕获用户个性化的动态兴趣变化, 削弱兴趣漂移对推荐性能带来的影响, 本文提出了一种基于用户长短期偏好的序列推荐模型 (ULSP-SRM)。首先, 将用户的行为序列按天切分成会话表示, 然后根据序列中交互物品的类别和时间信息生成用户的动态类别嵌入, 以最后一天的行为序列作为用户的短期偏好序列; 其次, 根据用户当前点击物品和最后一项点击的时间间隔信息生成个性化时序位置嵌入矩阵, 与用户的长期偏好序列进行融合; 然后, 将融合了个性化时序位置嵌入矩阵的用户长期偏好序列以会话为单位输入 GRU (Gate Recurrent Unit) 中, 生成用户的长期偏好表示; 最后, 通过 Attention 机制将用户长短期偏好进行融合, 生成用户的最终兴趣偏好表示, 输入推荐预测层进行下一项推荐预测。

本文主要的贡献如下: 1) 针对用户点击物品间关联性弱的问题, 设计了结合用户点击物品时间的动态用户类别提取方式, 有效建立了物品之间的关联性, 并且降低了数据的稀疏性; 2) 针对用户的个性化行为现象, 设计了个性化时序位置矩阵, 以提取更丰富的特征表达; 3) 针对用户长短期动态偏好建模形式, 设计了融合 GRU 和 Attention 机制的用户偏好建模方式, 从而充分捕获用户偏好; 4) 提出了一种基于用户长短期偏好的序列推荐模型 (ULSP-SRM), 并在 7 个真实数据集上进行了实验, 结果表明本文模型优于其他先进基准模型。

2 相关工作

传统的机器学习方法可以用于序列推荐, 基于马尔可夫链 (Markov Chain, MC) 的方法将当前用户行为序列映射到马尔可夫链中, 根据该用户上一次的交互来预测下一时刻交互

过程中用户的举动。Rendle 等^[6]提出了 FPMC (Factorizing Personalized Markov Chains) 模型, 通过一种基于矩阵分解和一阶马尔可夫链相结合的混合方法来捕获序列模式和长期用户偏好并基于此进行推荐。然而, 基于马尔可夫链的方法通常侧重于建模两个相邻项的顺序转换。因此, 基于马尔可夫链的模型可能难以捕捉到用户的长期偏好。此外, 这些方法也不能有效地模拟原始上下文随时间的动态变化。相比之下, 本文提出的模型将顺序的交互序列划分为一系列的会话表示, 提取用户一定时间间隔内的动态兴趣变化。

基于神经网络的用户行为序列数据建模也被用于推荐系统。Hidasi 等^[7]提出了基于会话的推荐模型, 首次将 GRU 引入会话推荐中, 用于建模序列物品之间的关系。然后, Li 等^[8]通过引入数据增强技术, 扩展了文献^[7]中的方法。Liu 等^[9]提出了一种基于注意力的短期记忆网络, 可以在不使用 RNN 的情况下捕获用户当前的兴趣, 该网络使用注意机制来强调最后一次点击的重要性。Item-KNN^[10] (Item K-Nearest Neighbor) 可以通过推荐与当前用户行为序列的最后一个物品最相似的物品来进行下一项的推荐。然而, 只强调最后一次点击的重要性, 可能会出现噪声^[11]。相比之下, 本文提出的模型根据用户行为序列中点击物品的时间间隔信息提出时序位置参数矩阵, 然后将它们集成到序列推荐模型的会话表示中, 并且取最后一天的点击序列作为短期兴趣序列, 减少噪声。

基于神经注意力机制的方法被广泛应用于各种任务中。例如, Transformer^[12]自被提出以来已被广泛应用于自然语言处理、计算机视觉、推荐系统等领域。CSAN (Contextual Self-attention Network) 模型^[13]引入了特征级神经自注意力机制, 以便更好地发现序列内部的相关性, 由于这需要大量的参数, 因此增加了模型的复杂性。SHAN (Sequential Hierarchical Attention Network) 模型^[14]利用原始的注意机制来捕获用户的长期和短期偏好, 并通过用户嵌入来引入上下文信息, 但它忽略了长期行为中的时间衰减和每个特征维度中的用户-物品相关性。相比之下, 本文模型以会话的形式对用户的长短期偏好进行建模, 有效减少了参数量, 从而提升了推荐性能。

3 基于用户长短期偏好的序列推荐模型

3.1 问题定义

本节对用户长短期序列推荐进行形式化定义, 包括对所研究问题的正式描述和相关符号含义说明, 并给出了本文使用的主要符号的定义。

设数据集中用户集合 $U = \{u_1, u_2, \dots, u_p\}$, 交互物品集合 $V = \{v_1, v_2, \dots, v_q\}$, 类别集合 $C = \{c_1, c_2, \dots, c_h\}$, 其中 p, q 和 h 分别为用户、交互物品和类别的个数。对于每个用户 $u \in U$, 我们将用户 u 的行为序列根据时间戳按天进行了划分, 用户 u 的行为序列定义为 $L_T^u = \{S_1^u, S_2^u, \dots, S_T^u\}$, 其中 T 表示当前的时间, $S_i^u \subseteq V (i \in [1, T])$ 表示用户 u 在时间 i 时的会话, 每个会话代表用户在一天内的行为序列。由于会话 S_T^u 包含了用户 u 最近一天内的点击物品行为, 这反映了用户 u 在 T 时的短期兴趣, 我们称 S_T^u 为用户 u 的短期兴趣序列。那么, 我们称用户 u 在时间 $1 \sim (T-1)$ 的行为序列 $L_{T-1}^u = \{S_1^u, S_2^u, \dots, S_{T-1}^u\}$ 为其长期偏好序列。

所研究问题可正式描述为:给定用户的行为序列 L_T^u , 预测目标用户的下一个行为,并向目标用户推荐合适的物品。

3.2 ULSP-SRM 模型描述

本文提出的 ULSP-SRM 模型主要包括 4 个部分,如图 1 所示。

(1)序列切分与动态用户类别提取。首先将用户 u 的行为序列根据时间戳按天划分成会话表示,得到用户 u 的行为序列 $L_T^u = \{S_1^u, S_2^u, \dots, S_T^u\}$;接下来从 L_T^u 和 C 中获取用户的动态类别,其被表示为 C_T^u ,然后利用 C_T^u 从物品类别集合 C 中查找并生成用户 u 在时间 T 时的动态用户类别嵌入层。我们将长期序列的长度限制为 L_s ,因此 $L_{T-1}^u = \{L_{n-L_s}, \dots, L_j, \dots, L_n\}$,其中 n 为 L_{T-1}^u 中最后一个交互物品的索引编号。

(2)个性化时序位置矩阵嵌入。本文提出了可训练的个性化时序位置嵌入,用 $P^u = \{p_{n-L_s}, \dots, p_j, \dots, p_n\}$ 表示,用于对用户的长期历史行为序列进行建模,捕获用户特定时间的个性化兴趣偏好,从而得到融入了时序位置嵌入矩阵的用户长期历史行为表示 $H_{T-1}^u = \{h_{n-L_s}, \dots, h_j, \dots, h_n\}$ 。

(3)用户长短期动态偏好提取层。本文将融入了时序位置嵌入矩阵的用户长期历史行为序列 H_{T-1}^u 以每个会话为单位输入 GRU 单元中,得到用户的长期动态兴趣偏好。然后采用神经注意力机制将用户的短期兴趣序列 S_T^u 和用户的长期偏好序列 L_{T-1}^u 进行融合,得到用户的最终兴趣偏好表示。

(4)推荐预测层。将用户的最终动态兴趣偏好表示输入全连接层中得到最终的预测结果。

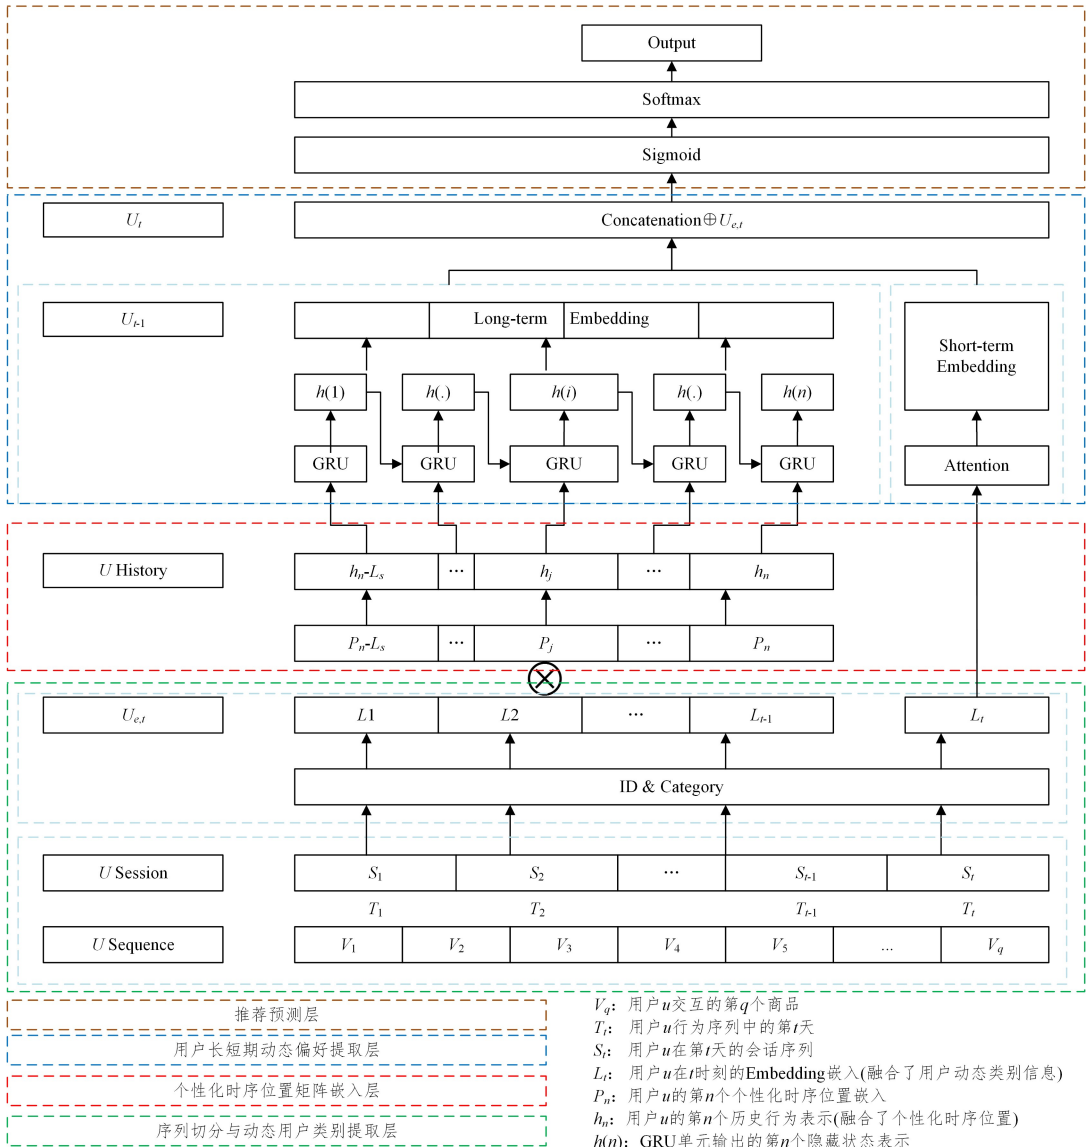


图 1 ULSP-SRM 模型图

Fig. 1 ULSP-SRM model diagram

3.3 序列切分与动态用户类别提取层

在根据用户的行为序列进行推荐之前,需要将用户、交互物品和历史交互序列的原始特征输入嵌入层转换为对应的 Embedding 向量,然后将历史交互 Embedding 向量输入序列切分与动态用户类别提取层,以挖掘用户的丰富特征。Em-

bedding 技术是将大尺度稀疏特征转换为低维密集向量的一种常用技术。从数学的角度来讲,稀疏特征可以分别用 $E \in \mathbf{R}^{M \times d}$ 表示,其中 M 为稀疏特征的大小, d 为 Embedding 向量维度大小。通过 Embedding 操作,用户特征信息可以用 $X^U \in \mathbf{R}^{N_u \times d}$ 来表示,其中 N_u 是用户的稀疏特征的数量, d 为

隐藏特征的大小。物品特征信息可以用 $\mathbf{X}^V \in \mathbf{R}^{N_p \times d}$ 表示,其中 N_p 为交互物品的稀疏特征的数量。接下来根据用户的历史交互 Embedding 向量进行序列切分和动态用户类别提取。

3.3.1 序列切分层

为了提取更精确的用户兴趣,受 Grbovic 等^[15]的启发,我们将用户的行为序列 L_u^i 根据交互物品的时间戳按天划分为多个会话 S , 用户 u 的行为序列定义为 $\mathbf{L}_u^i = \{S_1^i, S_2^i, \dots, S_T^i\}$, 其中 T 表示当前的时间, $S_i^i \subseteq V (i \in [1, T])$ 表示用户 u 在时间 i 时的会话, 每个会话代表用户在一天内的行为序列, 会话 S_i^i 包含了用户 u 最近一天内的点击物品行为, 取其中最会长会话长度 l_{\max} 作为每个会话的长度, 长度不足的采用 padding 填充, 从而得到用户 u 的行为序列的会话表示。

3.3.2 动态用户类别提取层

接下来我们进行动态用户类别提取, 现有方法大多都是将用户进行隐式的分组, 如基于用户的协同过滤算法^[16-18]和基于社交网络的协同过滤算法^[19-20], 它们不能明确地建模物品类别之间的相关性。此外, 一些研究^[21-22]以高时间复杂度为代价, 明确地将用户类别信息作为用户的特征。此外, 用户的类别可能会随着时间动态变化, 在每个时间位置将用户建模为特定的类别是不准确的。特别是, 用户 u 在 t 时刻最感兴趣的物品类别可以被认为是她/他当前的物品类别, 从而在类别中包含了很强的用户-用户和用户-物品之间的相关性。因此, 从用户 u 的 L_u^i 中选择最频繁的物品类别作为 t 时刻用户 u 的类别, 得到动态用户类别, 用 C_u^i 表示, 这个是在模型训练之前完成的。然后利用查表操作从物品类别集合 C 中提取用户类别 Embedding 向量, 并将其与用户 ID 的 Embedding 向量进行连接, 得到用户 u 在 t 时刻的 Embedding 嵌入 $\mathbf{u}_{e,t}$ 。具体的操作方式如下:

$$\mathbf{u}_{e,t} = \text{Con}(U(\mathbf{u}), C(c_t^u)) \quad (1)$$

其中, $\mathbf{u}_{e,t} \in \mathbf{R}^{2d}$, $U(\cdot)$ 和 $C(\cdot)$ 分别表示通过用户 ID 和类别 Embedding 进行查表操作, $\text{Con}(\cdot)$ 表示将两者进行拼接的连接函数。特别地, 通过将 $U(\cdot)$ 替换为 $V(q)$ 并且将 c_t^u 替换为 c^h , 我们还可以获得交互物品动态类别 Embedding, 其中 $V(\cdot)$ 和 c^h 分别表示物品 ID 查表操作和物品类别。

3.4 个性化时序位置矩阵嵌入层

商家习惯在某一特定时间前后开展促销活动(如双十一、节日等), 这导致用户行为记录中存在大量密集和稀疏的空白。有些用户喜欢在促销期间领取大量优惠券凑单进行购物, 然而有些用户不习惯凑单等操作而选择在平时购物。我们称这种现象为“时序位置聚合”, 它可以隐式地反映相关的环境信息、偏好信息等。显然, 每个用户都有自己的个性化行为模式, 因此不同的人对相似的前后物品信息有不同的反应, 比如相同的“时序位置聚合”间隔时间, 这被称为“个性化时序位置聚合”现象。因为用户不同日期的会话序列长度不是固定的, 所以当前交互物品与要预测物品之间的距离包含更有效的信息。为了模拟用户行为序列中的“个性化时序位置聚合”现象, 并捕获用户特定的时间偏好, 我们提出了个性化的时序位置嵌入方法。

对于用户的每个交互物品 v , 都有一个时间戳值 t 。在之前的研究中, 这些绝对时间戳值被转换成单一的 Embedding 向量。然而, 考虑到用户的时序行为是个性化聚集的, 单一的嵌入可能还不够。Liu 等^[23]将用户的行为分为多种类型, 利用 log 双线性模型分别建模用户多种行为之间的短期情景信息。通过将 log 双线性中的特定位置转移矩阵替换为时间特定的转移矩阵, 来捕获时差信息在用户行为历史中的影响, 从而得到一个时间感知的循环 log 双线性模型。Zhou 等^[24]提出了用户微动作及其持续时间对用户行为的影响。为了解决以上问题, 受文献^[23-24]的启发, 我们采用位置编码和用户当前交互物品与用户最后一次点击物品的时间间隔关系编码相结合的方式, 来构建可训练的时序位置嵌入矩阵, 而不是采用传统的单一时间戳嵌入向量构建用户正向时间感知信息。我们采用绝对嵌入和相对嵌入的方法分别对位置信息和时序信息进行编码, 从而更充分地捕获用户特定的时间偏好。

绝对嵌入将用户会话序列中的每个位置编码为 $\mathbf{E}^{\text{Pos}} \in \mathbf{R}^{L_s \times d}$, 这里的位置嵌入只依赖于用户行为序列中交互物品的索引值, 而不依赖于交互物品的时间戳值。相对嵌入利用时间间隔信息将序列中用户当前交互物品与最后一次点击物品之间的关系编码为 $\mathbf{E}^{\text{Sin}}, \mathbf{E}^{\text{Exp}} \in \mathbf{R}^{L_s \times d}$ 。首先, 我们定义了一个相对时间间隔信息矩阵 $\mathbf{D} \in \mathbf{R}^{1 \times L_s}$:

$$\mathbf{D} = [d_{1q} \quad d_{2q} \quad \dots \quad d_{qq}] \quad (2)$$

相对时间间隔矩阵 \mathbf{D} 中的元素被定义为:

$$d_{aq} = \frac{|t_a - t_q|}{\gamma} \quad (3)$$

其中, γ 是一个全局可训练的时间间隔参数(我们取初始值为 1.0), a, q 分别为用户当前点击物品和会话序列最后点击物品的索引。我们接下来介绍 \mathbf{D} 所采用的 3 个编码函数。Sin 编码器通过式(4)将时间间隔 d_{aq} 转换为隐藏向量 $\vec{\theta}_{ab} \in \mathbf{R}^{1 \times d}$:

$$\vec{\theta}_{ab,2c} = \sin\left(\frac{d_{aq}}{\text{freq}^{\frac{2c}{d}}}\right), \vec{\theta}_{ab,2c+1} = \cos\left(\frac{d_{aq}}{\text{freq}^{\frac{2c}{d}}}\right) \quad (4)$$

其中, $\vec{\theta}_{ab,c}$ 代表向量 $\vec{\theta}_{ab}$ 的第 c 个值, freq 是一个可调节参数。同样地, Exp 编码器通过应用式(5)将时间间隔 d_{aq} 转换为隐藏向量 $\vec{e}_{aq} \in \mathbf{R}^{1 \times d}$:

$$\vec{e}_{aq,c} = \exp\left(\frac{-|d_{ab}|}{\text{freq}^{\frac{c}{h}}}\right) \quad (5)$$

通过多种混合编码方式, 每种嵌入关于时序数据从不同角度进行编码。例如, Sin 编码会捕获周期性发生的事件, 较大的时间间隔在 Exp 编码中迅速衰减到零, 这样可以根据时序位置信息为用户交互物品动态地分配不同的权重, 从而得到用户的动态兴趣变化。我们通过式(6)得到用户长期序列中个性化时序位置信息编码向量的表示:

$$\vec{P}_n = \vec{E}^{\text{Pos}} + (\mathbf{E}^{\text{Sin}} \mathbf{E}^{\text{Exp}}) \quad (6)$$

其中, 位置信息嵌入类似于文献^[25-26]中使用的可学习位置嵌入, 个性化时序位置信息编码向量 \vec{P}_n 对应每个位置在 $\mathbf{P}^u \in \mathbf{R}^{L_s \times d}$ 中都有一个对应位置的向量 \vec{E}_{pos} , 然后我们得到可训练的个性化时序位置嵌入:

$$\mathbf{P}^u = \{p_{n-L_s}, \dots, p_j, \dots, p_n\} \quad (7)$$

最后,我们可以通过式(8)获得融入了个性化时序位置的历史行为表示。

$$\mathbf{h}_j = p_j \otimes l_j \quad (8)$$

其中, \otimes 表示元素级的乘积, p_j 和 l_j 分别为融合个性化时序位置的历史行为表示和对应的长期行为序列中的第 j 个会话。 p_j 是用户 u 的第 j 个个性化时序位置嵌入。综上所述,用户 u 的长期历史会话行为被表示为:

$$\mathbf{H}_{T-1}^u = \{\mathbf{h}_{n-L_s}, \dots, \mathbf{h}_j, \dots, \mathbf{h}_n\} \in \mathbf{R}^{k \times d \times L_s} \quad (9)$$

3.5 用户长短期动态偏好提取层

在推荐系统中,用户的历史行为反映了用户的兴趣变化,在用户长短期动态偏好提取层,我们从连续的用户行为中提取出了一系列的兴趣状态。用户长短期动态偏好提取层可分为长期偏好建模层和短期兴趣建模层。

3.5.1 长期偏好建模层

LSTM^[27] (Long Short Term Memory) 和 GRU 都是循环神经网络的变体,它们一定程度上解决了神经网络中梯度消失的问题。由于 GRU 中的参数量比 LSTM 少,更容易进行训练,相比 LSTM,使用 GRU 能够达到更好的效果,能够很大程度地提高训练效率。为了平衡效率和性能之间的关系,我们采用 GRU 来建模用户长期行为之间的依赖关系。我们将融入了个性化时序位置嵌入的用户长期历史行为表示 \mathbf{H}_{T-1}^u 以每个会话为单位输入到 GRU 单元中,用前一个 GRU 单元的输出来初始化下一个 GRU 单元的隐藏状态,并将下一个会话作为 GRU 单元的输入,建模长期行为之间的依赖关系,通过式(10)~式(13)得到用户的长期动态兴趣偏好:

$$\mathbf{z}_t' = \delta(\mathbf{W}_z \mathbf{h}_j + \mathbf{P}_z \mathbf{h}_{t-1}') \quad (10)$$

$$\mathbf{r}_t' = \delta(\mathbf{W}_r \mathbf{h}_j + \mathbf{P}_r \mathbf{h}_{t-1}') \quad (11)$$

$$\tilde{\mathbf{h}}_t' = \tanh(\mathbf{W}_h \mathbf{h}_j + \mathbf{P}_h (\mathbf{r}_t' \cdot \mathbf{h}_{t-1}')) \quad (12)$$

$$\mathbf{h}_t' = (1 - \mathbf{z}_t') \cdot \mathbf{h}_{t-1}' + \mathbf{z}_t' \cdot \tilde{\mathbf{h}}_t' \quad (13)$$

其中, $\mathbf{z}_t' \in \mathbf{R}^{2d \times 2d}$ 和 $\mathbf{r}_t' \in \mathbf{R}^{2d \times 2d}$ 分别为重置门和更新门, \mathbf{W}_z , \mathbf{P}_z , \mathbf{W}_r , \mathbf{P}_r 和 \mathbf{W}_h , \mathbf{P}_h 分别为重置门、更新门和输出门的可学习参数, $\delta(\cdot)$ 为 Sigmoid 函数, \cdot 为点乘运算, \mathbf{h}_t' 为隐藏状态。采用前一个 GRU 单元的输出来初始化下一个 GRU 单元的隐藏状态 \mathbf{h}_t' , 不仅捕获了兴趣之间的相互依赖关系,而且能有效地表示用户长期动态变化的兴趣,我们将用户 u 各会话的 GRU 输出 \mathbf{h}_j' 进行聚合操作,最终生成用户 u 的长期偏好表示。

$$\mathbf{u}_{t-1} = \sum_{j=1}^{L_s} \mathbf{h}_j' \quad (14)$$

3.5.2 短期兴趣建模层

用户的长期兴趣偏好可以从他们的长期行为记录中推断出来,这并不能很好地代表他们最近的兴趣。特别是在稀疏的数据集中,对于下一个物品的推荐,短期的兴趣通常比用户的长期偏好更重要。

因此,我们将用户短期行为分开,以强调用户最近行为记录的作用。但是,仍然需要仔细考虑如何选择短期会话中物品的数量。根据行为经济学中的“峰值定律”^[28],最令人印象深刻和最后的物品通常对当前决策的影响最大。因此,将

之前的物品纳入长期偏好层,将最近一天发生的行为作为短期兴趣层。

此外,短期层还将用户的短期兴趣和长期偏好结合在一起。由于短期会话中的行为只发生在一天内,我们没有利用时序信息和位置嵌入来强调短期兴趣,从而降低了模型的复杂性。我们采用神经注意力机制,通过式(15)来捕获用户在每个维度中的短期兴趣:

$$\begin{aligned} \text{att}_j^s &= \text{Att}^{2d}(\mathbf{W}_1, \mathbf{W}_2, \mathbf{b}_1, \mathbf{b}_2, s_j) \\ &= \mathbf{W}_1^T \sigma(\mathbf{W}_2(s_j) + \mathbf{b}_2) + \mathbf{b}_1 \end{aligned} \quad (15)$$

$$[\mathbf{a}_j^s]_k = \frac{e^{[\text{att}_j^s]_k}}{\sum_{j=0}^{|\mathcal{S}_j^s|-1} e^{[\text{att}_j^s]_k}} \quad (16)$$

$$\mathbf{u}_t = \mathbf{u}_{e,t} \oplus \sum_{j=0}^{|\mathcal{S}_j^s|-1} \mathbf{a}_j^s \cdot s_j \quad (17)$$

其中, \oplus 是一个元素级加法, $\mathbf{W}_1, \mathbf{W}_2 \in \mathbf{R}^{2d \times 2d}$ 和 $\mathbf{b}_1, \mathbf{b}_2 \in \mathbf{R}^{2d}$ 是可训练的参数, $2d$ 表示在 $\text{Att}(\cdot)$ 中嵌入的维度。并且,我们选择 ReLU 作为激活函数 $\sigma(\cdot)$, 以增强非线性方面的能力。 $s_j \in \mathbf{R}^{2d}$, 当 $j > 0$ 时 $s_j \in \mathcal{S}_j^s$; 当 $j = 0$ 时, $s_j = \mathbf{u}_{t-1}$ 。我们应用 $\mathbf{u}_{e,t}$ 来添加上下文信息。

最后,用户 u 的当前兴趣偏好被表示为 \mathbf{u}_t , 这包含了用户长期动态兴趣偏好和短期兴趣。接下来就可以将用户的当前兴趣偏好表示输入推荐预测层,以推荐适合目标用户的下一个物品。

3.6 推荐预测层

我们用训练集中所有用户的行为记录来训练 ULSP-SRM 模型,然后预测测试集中的标签(物品)。具体来说,预测的标签越接近真实,模型就越有效。本文只需要预测下一个物品是否会被购买。因此,我们选择统一的 Sigmoid 交叉熵损失进行模型优化。

$$\begin{aligned} \text{Loss} &= - \sum_{u,j} y_j \log(\sigma(f(\mathbf{u}_t, s_j))) + (1 - y_j) \log(1 - \sigma(f(\mathbf{u}_t, \\ & s_j))) + \lambda \|\Theta\|^2 \end{aligned} \quad (18)$$

其中, $f(\cdot)$ 表示排序函数,可以是点积函数,或者是复杂深度神经网络, $\Theta = \{\mathbf{X}^U, \mathbf{X}^V, \mathbf{W}_*, \mathbf{b}_*\}$, λ 是 L_2 正则化系数,标签用 $y \in \{0, 1\}$ 表示, $\sigma(\cdot)$ 代表 Sigmoid 函数。

4 实验及分析

4.1 实验设置

为了验证本文所提出的 ULSP-SRM 模型的推荐性能,所有实验均在 Intel Core(TM) i5-4690 CPU@3.5GHz 和 16GB 内存、10GB 显存的 GTX2080Ti 显卡的 64 位 Ubuntu 系统中完成,本文模型基于 Tensorflow1.8.0 实现,使用 SGD 优化器进行训练。

4.2 数据集

为了评估本文模型的性能,本文在 Amazon 数据集上进行了实验验证。亚马逊是世界上最大的电子商务平台,拥有最大、最广泛的行为数据量。特别是,其产品涵盖了生活中的大部分领域,具有良好的多样性。亚马逊数据集过滤掉了少于 5 条评论的用户和物品,并删除了大量无效数据。在接下来的实验中,只使用了用户、物品、交互和类别信息。然后我们按照以下两步进行预处理,数据集的统计数据如表 1 所列。

表 1 实验数据集统计
Table 1 Statistics of datasets

| Datasets | users | items | categories | behaviors | Avg (items/category) | Avg (behaviors/item) | Avg (behaviors/user) |
|----------------|--------|--------|------------|-----------|-------------------------|-------------------------|-------------------------|
| Electronics | 39 991 | 22 048 | 673 | 561 100 | 32.8 | 25.4 | 14.0 |
| CDs-Vinyl | 24 179 | 27 602 | 310 | 470 087 | 89.0 | 17.0 | 19.4 |
| Clothing-Shoes | 2 010 | 1 723 | 226 | 13 157 | 7.6 | 7.6 | 6.5 |
| Movies-TV | 35 896 | 28 589 | 15 | 752 676 | 1 905.9 | 20.9 | 26.3 |
| Beauty | 3 783 | 2 658 | 179 | 54 225 | 14.8 | 20.4 | 14.3 |
| Home-Kitchen | 11 567 | 7 722 | 683 | 143 088 | 11.3 | 12.3 | 18.5 |
| Toys-Games | 2 677 | 2 474 | 221 | 37 515 | 11.2 | 15.2 | 14.0 |

首先,删除交互次数小于 10 的用户和交互物品个数小于 8 的用户,以确保每个用户和物品的有效性。其次,我们选择会话数超过 4 但小于 90 的用户,该步骤保证了长期和短期行为记录的存在,并且所有的行为记录都发生在最近 3 个月内。

4.3 评价指标

本文利用 3 种评估方法 AUC, Precision 和 Recall, 来评估模型,以捕获用户偏好和执行下一项推荐的能力。

实验中将数据集按照 8:1:1 分为训练集、验证集和测试集。对于分类任务采用 AUC 来评估模型的 CTR 预测性能, AUC 为 Receiver Operating Characteristic(ROC) 曲线下的坐标轴所包围的区域。在训练过程中,模型效果越好, AUC 值越大。在形式上, AUC 被定义为:

$$AUC = \frac{1}{|U|} \sum_{u \in U} \frac{1}{|S| |S'|} \sum_{s \in S} \sum_{s' \in S'} \xi(p_{u,s} > p_{u,s'}) \quad (19)$$

其中, S 和 S' 分别表示正样本集和负样本集; $p_{u,s}$ 表示用户 u 在测试集中选择正样本 s 的预测概率;同理, s' 表示负样本; $\xi(\cdot)$ 是一个指标函数,当 $p_{u,s} > p_{u,s'}$ 时, $\xi(p_{u,s} > p_{u,s'}) = 1$, 否则为 0。

Precision@K 和 Recall@K 中 K 表示只考虑 top-K 物品。在形式上,它们的定义如下:

$$Precision@K = \frac{1}{|U|} \sum_{u \in U} \frac{\sum_{s=1}^K f_q(s, pos(u))}{K} \quad (20)$$

$$Recall@K = \frac{1}{|U|} \sum_{u \in U} \frac{\sum_{s=1}^K f_q(s, pos(u))}{NK(u)} \quad (21)$$

其中, $pos(u)$ 表示与用户 u 真实相关物品的集合; $NK(u)$ 表示用户 u 的 top-K 预测项中正样本的数量; $f_q(s, pos(u))$ 是一个指标函数,如果 $s \in pos(u)$, 则 $f_q(s, pos(u)) = 1$, 否则为 0。

4.4 实验对比基准模型介绍

在对比模型上,实验分别选取了基于贝叶斯个性化排序的推荐模型 BPR-MF^[29]、基于循环神经网络的推荐模型 Bi-

LSTM^[30]、基于位置信息的推荐模型 PACA^[31] (Position Aware Context Attention)、CSAN、基于用户长短期兴趣的 LSPM^[32] (long Short Term Preference Model) 和 SHAN。对比模型的介绍如下。

(1) BPR-MF: 贝叶斯个性化排序通过训练用户的正负样本对,以最小化每个用户差异的后验概率。

(2) Bi-LSTM: 为了捕获序列之间前向和后向的相关性,该模型采用双向长期和短期记忆网络进行序列推荐。

(3) PACA: 该模型通过多层感知器捕获每个物品的上下文和相应的会话,作为一个特定于会话的特征向量,注意力得分是由这两个向量产生的。

(4) CSAN: 该模型简单地将不可训练的位置编码矩阵添加到特征级自注意力机制中,通过自注意力神经网络生成用户行为 Embedding。

(5) LSPM: 该模型通过一个可训练矩阵中的向量捕获每个用户的长期偏好。然后,它将每个用户最近的 k 个物品的嵌入组合在一起,以模拟用户的短期偏好。

(6) SHAN: 长期和短期的行为记录都很重要,因此该模型提出了非线性层次注意网络来捕捉长期和短期用户的偏好。

4.5 实验结果与分析

4.5.1 实验结果比较

表 2 列出了本文所提出的 ULSP-SRM 模型和其他基准模型在 Amazon 数据集上的 AUC 指标的对比结果。为了保证实验的公平性和可比性,我们保持各模型中的公共参数相同,唯一参数为最优。对于所有模型,我们将用户、物品的表示向量维度设置为 32,训练时 BATCH_SIZE 大小设置为 32,测试时 BATCH_SIZE 大小设置为 128。从表 2 中可以看到,本文模型在 Amazon 的 7 个子数据集上的 AUC 指标的表现都优于对比模型。

表 2 在 Amazon 公开数据集上的 AUC 实验结果

Table 2 AUC experiment results on Amazon public datasets

| Datasets | BPR-MF | CSAN | LSPM | PACA | Bi-LSTM | SHAN | ULSP-SRM |
|----------------|--------|--------|--------|--------|---------|--------|---------------|
| Electronics | 0.7457 | 0.8005 | 0.7333 | 0.8322 | 0.8495 | 0.7542 | 0.8939 |
| CDs-Vinyl | 0.7684 | 0.7943 | 0.8594 | 0.8919 | 0.8969 | 0.7138 | 0.9587 |
| Clothing-Shoes | 0.6283 | 0.5866 | 0.6443 | 0.5313 | 0.7004 | 0.7284 | 0.8751 |
| Movies-TV | 0.7654 | 0.7958 | 0.8003 | 0.8055 | 0.8743 | 0.7771 | 0.9063 |
| Beauty | 0.6846 | 0.7650 | 0.7663 | 0.8979 | 0.8189 | 0.7821 | 0.9241 |
| Home-Kitchen | 0.6352 | 0.6820 | 0.6672 | 0.8165 | 0.7373 | 0.8230 | 0.8538 |
| Toys-Games | 0.6294 | 0.7157 | 0.7708 | 0.8495 | 0.8012 | 0.8797 | 0.9092 |

图 2 给出了 ULSP-SRM 模型和其他基准模型在 Beauty

数据集上的 Recall@K 和 Precision@K 实验结果,这里 K

分别 1,10,20,30,40 和 50。我们通过动态用户类别提取和可训练的个性化时序位置嵌入来学习用户特定的时间偏好。其次,设计用户长短期偏好建模层,增强了模型处理稀疏交互数据的能力,以有效地捕获用户的偏好。从图 2 中可以看出,本文方法具有明显的优势。

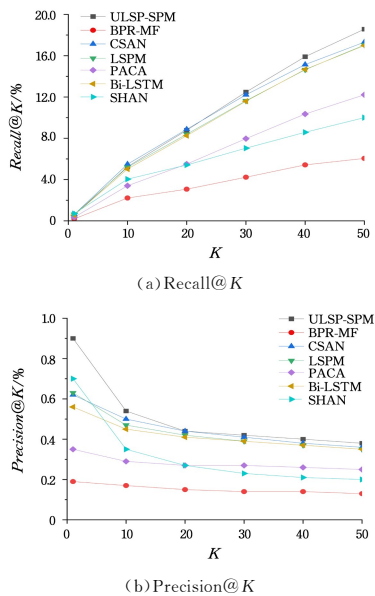


图 2 在 Beauty 数据集上 Recall@K 和 Precision@K 的实验结果
Fig. 2 Results of Recall@K and Precision@K on Beauty datasets

4.5.2 各参数对模型的影响

我们在 Amazon 的 Beauty 数据集上进行各参数分析实验,主要分析了用户-物品维度 d 和长期序列长度 L_s 的影响。每次实验中,我们只改变当前要研究的参数值,其他参数保持不变。

(1) 用户和物品维度 d 的影响

在 ULSP-SRM 模型中,参数 d 是一个很重要的参数, d 越大,其向量表示越复杂。

表 3 列出了不同 d 取值下,ULSP-SRM 模型在 Beauty 数据集上 AUC 的表现。本文设置了 4 组参数 d 分别进行实验,从表 4 和图 3(a)中可以看到,维度每次增加 16,当 d 趋近于 32 时,模型在 AUC 指标上表现最好。这是由于随着维度的增加,特征的数量也会增加,这使得模型能够捕获更多的特征或信息,以牺牲效率为代价,获得更高的精度。当 d 大于 32 时,随着维度的增加,出现过拟合现象,模型效果没有提升反而缓慢下降。根据图 6 中 Precision@20 和 Recall@20 的结果,随着嵌入维度的增加,模型的推荐能力也达到了顶峰。为了达到效率和精度之间的平衡,参数 d 被设置为 32。

表 3 在 Beauty 数据集中不同 d 的 AUC 值

Table 3 AUC values of different d on Beauty datasets

| d | 16 | 32 | 48 | 64 |
|-----|--------|--------|--------|--------|
| AUC | 0.9126 | 0.9241 | 0.9204 | 0.9183 |

(2) 长期序列长度 L_s 的影响


模型中长期序列长度 L_s 同样是一个重要的参数,如表 4 和图 3(b)所示,ULSP-SRM 模型可以通过不同的 L_s 捕获用户的长期偏好,当 $L_s = 10$ 时,ULSP-SRM 模型在 Precision@

20 和 Recall@20 指标上表现最好,这说明模型的推荐预测能力已经达到顶峰。因此,本文将参数 L_s 设置为 10。


表 4 在 Beauty 数据集中不同 L_s 的 AUC 值

Table 4 AUC values of different L_s on Beauty datasets

| L_s | 5 | 10 | 15 | 20 |
|-------|--------|--------|--------|--------|
| AUC | 0.9006 | 0.9241 | 0.9246 | 0.9225 |



(a) $L_s = 10$ 时, d 对模型的影响



(b) $d = 32$ 时, L_s 对模型的影响

图 3 在 Beauty 数据集上不同 d 和 L_s 情况下 Recall@20 和 Precision@20 的实验结果

Fig. 3 Experimental results of Recall@20 and Precision@20 with different d and L_s conditions on Beauty datasets

4.5.3 模型方法的消融实验

为了验证本文提出的个性化时序位置嵌入层和用户长短期动态偏好提取层对推荐性能的影响,在 Beauty 和 Toys-Games 数据集上通过以下实验进行对比验证。

(1) 将去掉个性化时序位置嵌入层和用户长短期动态偏好提取层后的 ULSP-SRM 模型作为基线模型,记为 Base 模型。在 Base 模型的基础上增加个性化时序位置嵌入层,记为 Base-TP 模型。两种模型在 Beauty 和 Toys-Games 数据集上的 AUC 和 Recall@20 和 Precision@20 指标上的表现如表 5 所列,可以看到,在 Beauty 数据集上,使用了个性化时序位置嵌入层后的模型在 AUC 指标上对比 Base 模型最大提升了 2.13%,在 Recall@20 和 Precision@20 指标上对比 Base 模型分别提升了 4.58% 和 0.20%;在 Toys-Games 数据集上,使用了个性化时序位置嵌入层后的模型在 AUC 指标上对比 Base 模型最大提升了 1.68%,在 Recall@20 和 Precision@20 指标上对比 Base 模型分别提升了 2.38% 和 0.12%。使用了个性化时序位置嵌入层来模拟用户行为序列中“个性化时序位置聚合”现象,并设置一个全局可训练参数,在训练时自动调整位置嵌入的数量级,从而与历史嵌入的数量级保持一致,充分挖掘用户的动态兴趣偏好信息。由实验结果可以得出,本文提出的个性化时序位置嵌入层,可以有效地模拟序列推荐中用户个性化聚合现象,从而提升推荐的性能。

表 5 Beauty 和 Toys-Games 数据集上的实验结果

Table 5 Experiment results on Beauty and Toys-Game datasets

| Models | Beauty | | | Toys-Games | | |
|----------|---------------------------|---------------------------|---------------------------|---------------------------|---------------------------|---------------------------|
| | AUC | Recall@20 | Precision@20 | AUC | Recall@20 | Precision@20 |
| Base | 0.8988 | 0.0431 | 0.0022 | 0.8804 | 0.0383 | 0.0019 |
| Base-TP | 0.9201 (+2.13%) | 0.0889 (+4.58%) | 0.0042 (+0.20%) | 0.8970 (+1.68%) | 0.0621 (+2.38%) | 0.0031 (+0.12%) |
| Base-LS | 0.9109 (+1.21%) | 0.0788 (+3.57%) | 0.0039 (+0.17%) | 0.8980 (+1.76%) | 0.0563 (+1.80%) | 0.0029 (+0.10%) |
| ULSP-SRM | 0.9241 (+2.53%) | 0.0878 (+4.47%) | 0.0044 (+0.22%) | 0.9092 (+2.88%) | 0.0611 (+2.28%) | 0.0036 (+0.17%) |

(2)对比 Base 模型,在 Base 模型的基础上增加长短期动态偏好提取层,记为 Base-LS 模型。两种模型在 Beauty 和 Toys-Games 数据集上的 AUC, Recall@20 和 Precision@20 指标上的表现如表 5 所列,可以看到,在 Beauty 数据集上,使用了长短期动态偏好提取层后的模型在 AUC 指标上对比 Base 模型最大提升了 1.21%,在 Recall@20 和 Precision@20 指标上对比 Base 模型分别提升了 3.57%和 0.17%;在 Toys-Games 数据集上,使用了长短期动态偏好提取层后的模型在 AUC 指标上对比 Base 模型最大提升了 1.76%,在 Recall@20 和 Precision@20 指标上对比 Base 模型分别提升了 1.80%和 0.10%。我们根据用户的行为序列将其兴趣分为长期和短期偏好,设计了长短期动态偏好提取层,并挖掘用户的个性化的时序位置偏好,从而有效地处理稀疏的交互数据。此外,我们通过动态用户类别提取挖掘了用户-用户和用户-物品之间的相关性,进而更加充分地捕获了用户的动态兴趣偏好。由实验结果可以得到,本文提出的长短期动态偏好提取层,可以有效削弱序列推荐中兴趣漂移的影响,从而提升推荐的性能。

(3)对比 Base 模型,在 Base 模型的基础上同时增加个性化时序位置嵌入层和用户长短期动态偏好提取层,从而得到 ULSP-SRM 模型。两种模型在 Beauty 和 Toys-Games 数据集上的 AUC, Recall@20 和 Precision@20 指标上的表现如表 5 所列,可以看到,在 Beauty 数据集上, AUC 指标对比 Base 模型最大提升了 2.53%,在 Recall@20 和 Precision@20 指标上对比 Base 模型分别提升了 4.47%和 0.22%;在 Toys-Games 数据集上, AUC 指标对比 Base 模型最大提升了 2.88%,在 Recall@20 和 Precision@20 指标上对比 Base 模型分别提升了 2.28%和 0.17%。由此可以得出,本文提出的个性化位置嵌入的长短期序列推荐模型是有效可行的,能有效解决用户兴趣漂移问题。

结束语 本文探讨了用户长短期偏好在序列推荐中的影响,提出了基于用户长短期偏好的序列推荐模型(ULSP-SRM)。该模型结合序列中的时间特性有效提取了用户的动态类别,并采用时序位置矩阵嵌入的方式模拟了用户的“个性化时序位置聚合”现象,充分挖掘和提取了用户的动态兴趣偏好。创新性地结合 GRU 以会话形式建模用户的长期动态偏好,采用注意力机制融合用户长短期偏好,有效地解决了用户兴趣漂移的问题。我们将所提模型在 Amazon 的 7 个子数据集上与其他先进的基准模型进行对比实验,本文模型表现出了优异的推荐性能。

本文模型目前仅采用了商品类别信息和时间信息,在今后的研究中,将考虑更加丰富的上下文信息,如地域因素、

社交关系等辅助信息,以更加充分地挖掘用户的长短期偏好。

参 考 文 献

- [1] WANG S, CAO L, WANG Y, et al. A survey on session-based recommender systems[J]. ACM Computing Surveys (CSUR), 2021, 54(7):1-38.
- [2] PÉREZ-ALMAGUER Y, YERA R, ALZHRANI A A, et al. Content-based group recommender systems: A general taxonomy and further improvements[J]. Expert Systems with Applications, 2021, 184:115444.
- [3] CHEN X, XU H, ZHANG Y, et al. Sequential recommendation with user memory networks[C]// Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining. 2018:108-116.
- [4] WANG N, HE X M, LIU Z Q, et al. A personalized video recommendation strategy based on user playing behavior sequences [J]. Chinese Journal of Computers, 2020, 43(1):123-135.
- [5] CHEN J P, HU H L, ZHANG F, et al. Convolutional sequential recommendation with temporal feature and user preference[J]. Computer Science, 2022, 49(1):115-120.
- [6] 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. 2010:811-820.
- [7] HIDASI B, KARATZOGLOU A, BALTRUNAS L, et al. Session-based recommendations with recurrent neural networks [J]. arXiv:1511.06939, 2015.
- [8] LI J, REN P, CHEN Z, et al. Neural attentive session-based recommendation[C]// Proceedings of the 2017 ACM on Conference on Information and Knowledge Management. 2017:1419-1428.
- [9] 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 & Data Mining. 2018:1831-1839.
- [10] WANG M, REN P, MEI L, et al. A collaborative session-based recommendation approach with parallel memory modules[C]// Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. 2019:345-354.
- [11] XING C Z, ZHU J X, MENG X F, et al. Research review on recommendation methods for points of interest[J]. Computer Science, 2021, 48(11A):176-183.

- [12] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]// Advances in Neural Information Processing Systems. 2017;5998-6008.
- [13] HUANG X, QIAN S, FANG Q, et al. Csan; Contextual self-attention network for user sequential recommendation[C]// Proceedings of the 26th ACM International Conference on Multimedia. 2018;447-455.
- [14] YING H, ZHUANG F, ZHANG F, et al. Sequential recommender system based on hierarchical attention network[C]// IJCAI International Joint Conference on Artificial Intelligence. 2018;3926-3932.
- [15] GRBOVIC M, CHENG H. Real-time personalization using embeddings for search ranking at airbnb[C]// Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2018;311-320.
- [16] CHEN J, WANG X, ZHAO S, et al. Deep attention user-based collaborative filtering for recommendation[J]. Neurocomputing, 2020,383(C);57-68.
- [17] KOOHI H, KIANI K. User based collaborative filtering using fuzzy c-means[J]. Measurement, 2016,91;134-139.
- [18] BELLOG A, PARAPAR J. Using graph partitioning techniques for neighbour selection in user-based collaborative filtering [C]// Proceedings of the Sixth ACM Conference on Recommender Systems. 2012;213-216.
- [19] TIAN Z, PAN L M, YIN P, et al. Recommendation algorithm for deep matrix factorization [J]. Journal of Software, 2021,32(12);3917-3928.
- [20] QIAN X, FENG H, ZHAO G, et al. Personalized recommendation combining user interest and social circle[J]. IEEE Transactions on Knowledge and Data Engineering, 2013,26(7);1763-1777.
- [21] CAI H N, NIU B H, WEN J H, et al. Recommendation algorithm based on time series model and matrix factorization[J]. Computer Application Research, 2018,35(6);1624-1627.
- [22] WANG N, HE X M, LIU Z Q, et al. A personalized video recommendation strategy based on user playing behavior sequences [J]. Journal of Computers, 2020,43(1);123-135.
- [23] LIU Q, WU S, WANG L. Multi-behavioral sequential prediction with recurrent log-bilinear model [J]. IEEE Transactions on Knowledge and Data Engineering, 2017,29(6);1254-1267.
- [24] ZHOU M, DING Z, TANG J, et al. Micro behaviors: A new perspective in e-commerce recommender systems[C]// Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining. 2018;727-735.
- [25] KENTON J D M W C, TOUTANOVA L K. Bert: Pre-training of deep bidirectional transformers for language understanding [C]// Proceedings of NAACL-HLT. 2019;4171-4186.
- [26] SUN F, LIU J, WU J, et al. BERT4Rec: Sequential recommendation with bidirectional encoder representations from transformer [C]// Proceedings of the 28th ACM International Conference on Information and Knowledge Management. 2019;1441-1450.
- [27] GRAVES A. Long short-term memory[M]// Supervised Sequence Labelling with Recurrent Neural Networks. Berlin/Heidelberg; Springer, 2012;37-45.
- [28] DO A M, RUPERT A V, WOLFORD G. Evaluations of pleasurable experiences: The peak-end rule[J]. Psychonomic Bulletin & Review, 2008,15(1);96-98.
- [29] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: Bayesian personalized ranking from implicit feedback[J]. arXiv: 1205.2618, 2012.
- [30] JOZEFOWICZ R, ZAREMBA W, SUTSKEVER I. An empirical exploration of recurrent network architectures[C]// International Conference on Machine Learning. PMLR, 2015;2342-2350.
- [31] CAO Y, ZHANG W, SONG B, et al. Position-aware context attention for session-based recommendation[J]. Neurocomputing, 2020,376(C);65-72.
- [32] DU Y, LIU H, QU Y, et al. Online personalized next-item recommendation via long short term preference learning[C]// Pacific Rim International Conference on Artificial Intelligence. Cham; Springer, 2018;915-927.



LUO Xiaohui, born in 1998, postgraduate, is a student member of China Computer Federation. His main research interests include artificial intelligence and big data, data mining and recommendation system.



WU Yun, born in 1973, Ph.D, associate professor, is a senior member of China Computer Federation. His main research interests include artificial intelligence, computer vision, deep learning and recommendation system.

(责任编辑:喻黎)