

## 一种时序情感记忆可约束可解释的序列推荐方法

郑麟, 林艺璇, 周东霖, 朱福喜

引用本文

郑麟, 林艺璇, 周东霖, 朱福喜. 一种时序情感记忆可约束可解释的序列推荐方法[J]. 计算机科学, 2023, 50(6A): 220100066-8.

ZHENG Lin, LIN Yixuan, ZHOU Donglin, ZHU Fuxi. [Explainable Constraint Mechanism for Modeling Temporal Sentiment Memory in Sequential Recommendation](#) [J]. Computer Science, 2023, 50(6A): 220100066-8.

---

## 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  
计算机科学, 2023, 50(4): 47-55. <https://doi.org/10.11896/jsjx.220100264>

### [一种基于修饰关系的自然语言语义分析方法](#)

New Approach to Analyzing Meaning of Natural Language on Modifying Relations  
计算机科学, 2010, 37(5): 197-202.

### [上下文分解机的自适应更新策略](#)

Adaptive Parameters Updating Strategy of Context-aware Factorization Machines  
计算机科学, 2016, 43(9): 71-76. <https://doi.org/10.11896/j.issn.1002-137X.2016.09.013>

### [Web请求的时延刻画和降低时延的协作分配模型](#)

计算机科学, 2003, 30(5): 129-131.

### [基于支持向量机的两阶段模糊聚类在视频检索中的应用](#)

计算机科学, 2009, 36(6): 227-230.

# 一种时序情感记忆可约束可解释的序列推荐方法

郑麟<sup>1</sup> 林艺璇<sup>1</sup> 周东霖<sup>1</sup> 朱福喜<sup>2</sup>

1 汕头大学工学院 广东 汕头 515063

2 武汉大学计算机学院 武汉 430072

**摘要** 序列推荐研究近年来在推荐领域中发展迅速,已有的序列推荐方法善于捕捉用户的时序行为来实现偏好预测。其中,一些先进的方法融入用户的情感信息来引导行为挖掘。然而,先进的基于情感的序列推荐模型未考虑对多类别的用户情感序列进行关联挖掘;并且,这类方法无法直观地解释时序情感对用户偏好的贡献。为了弥补上述方法的局限,本工作首次尝试以记忆体的形式存储时序情感并对其施加约束。具体地,文中提出了情感自我约束和情感相互约束两种机制,来挖掘多类别情感之间的关联并辅助用户行为完成序列推荐。进一步地,提出的记忆框架能记录用户的时序情感注意力,从而在准确预测用户时序偏好的基础上提供一定程度的直观解释。实验结果表明,所提方法的性能优于先进的序列推荐方法,并且比基于情感的序列推荐模型具有更好的可解释效果。

**关键词:** 序列推荐;时序情感;情感记忆;情感约束;可解释推荐

**中图法分类号** TP311

## Explainable Constraint Mechanism for Modeling Temporal Sentiment Memory in Sequential Recommendation

ZHENG Lin<sup>1</sup>, LIN Yixuan<sup>1</sup>, ZHOU Donglin<sup>1</sup> and ZHU Fuxi<sup>2</sup>

1 College of Engineering, Shantou University, Shantou, Guangdong 515063, China

2 School of Computer Science, Wuhan University, Wuhan 430072, China

**Abstract** In recent years, the research of sequential recommendation has developed rapidly in the recommendation field, existing methods are good at capturing users' sequential behavior to achieve preference prediction. Among them, some advanced methods integrate users' sentiment information to guide behavior mining. However, the advanced sentiment-based models do not consider mining relations between multi-category user sentiment sequences. Moreover, such methods cannot intuitively explain the contribution of temporal sentiments to user preferences. To make up for the above shortcomings, this paper first attempts to store temporal sentiments in the form of memory and impose constraints on them. Specifically, this research proposes two mechanisms including sentiment self-constraint and sentiment mutual-constraint to explore the associations between multiple categories of sentiments and assist user behaviors in completing sequential recommendations. Furthermore, the proposed memory framework is able to record users' temporal sentiment attention, so that it can provide a certain degree of intuitive explanation on the basis of accurately predicting users' temporal preference. Experimental results show that our approach outperforms existing state-of-the-art sequential methods, and it has better explainable effects than the sentiment-based sequential recommendation models.

**Keywords** Sequential recommendation, Temporal sentiment, Sentiment memory, Sentiment constraint, Explainable recommendation

## 1 引言

在推荐技术高度发展的今天,用户对推荐系统的期望已不再简单地局限于该系统能将用户可能喜欢的某些物品推送给她/他<sup>[1]</sup>,而是进一步希望推荐模型能捕获用户连续的长期的偏好并从更主观的角度为她/他推荐其真正喜欢的物品。其中,“捕获用户连续的长期的偏好”就是序列推荐(Sequential recommendation)要完成的任务;而“从主观的角度进行推荐”则着重考虑如何基于用户的主观因素(比如情感)完成

推荐(Sentiment-based recommendation)。当前序列推荐的研究<sup>[2]</sup>已十分成熟与先进,例如,以循环神经网络(Recurrent Neural Network, RNN)<sup>[3-4]</sup>为基本结构加入注意力机制(Attention mechanism)<sup>[5]</sup>捕获用户前后行为的关联,或以记忆网络(Memory Networks, MemNN)<sup>[6]</sup>为载体进行知识的扩充与建模。另一方面,基于情感因素的推荐研究比序列推荐起步更早,例如对用户情感分数和用户评分进行互补建模<sup>[7]</sup>,或者直接把情感当作用户评价的偏移完成偏好挖掘<sup>[8]</sup>。这些早期基于情感的工作并不直接面向序列推荐任务,而少数对时序

基金项目:国家自然科学基金(61902231);广东省基础与应用基础研究基金(2023A1515011240, 2020A1515010531);广东教育科学规划课题高等教育专项(2021GXJK241)

This work was supported by the National Natural Science Foundation of China(61902231), Guangdong Basic and Applied Basic Research Foundation(2023A1515011240, 2020A1515010531) and Higher Education Special Project of Guangdong Education Science Planning(2021GXJK241).

通信作者:郑麟(lzheng@stu.edu.cn)

情感进行挖掘的工作仅仅服务于传统推荐<sup>[9]</sup>。近年来,基于情感的序列推荐研究刚刚起步,代表性的方法为 Zheng 等<sup>[10]</sup>提出的 SGS 序列推荐模型(Sentiment-Guided Sequential recommender)。SGS 采用双通道结构对用户行为序列和情感序列进行挖掘并在最后完成偏好融合,其中,注意力机制<sup>[11-12]</sup>在两类序列建模中起到了关键作用。SGS 的性能比一些先进的序列推荐模型更好;然而,由于情感序列与行为序列的性质不同,基于情感的序列推荐任务仍然面临以下问题。

(1) 用户行为序列的对象是物品,而用户情感序列的对象是某类情感的值(程度),这两类对象的特性不适合都采用一类统一的序列建模方式(如注意力机制)进行建模。

(2) 与用户行为序列相比,用户情感序列具有多样化的特征,即用户的情感序列包含多种类别的情感极性,如 Very Positive, Positive, Negative 等,已有的研究工作并未对多类别的情感序列间的关系进行挖掘,从而没有将用户情感的贡献完全发挥出来。

(3) 现有的先进的工作利用情感序列引导行为序列的挖掘,在偏好预测时获得了较好的效果。然而,情感的引导效果无法直观地被展示出来。换句话说,先进的基于情感的序列深度模型采用黑盒式的设计,导致其无法解释情感在用户时序偏好挖掘中的贡献,即模型缺乏可解释能力。

针对上述挑战,本文提出了情感记忆可约束的序列推荐模型 SMC(Sentiment Memory-Constrained sequential recommender)来尝试解决这些问题,本工作的贡献如下:

(1) 为了解决情感序列与行为序列性质不同的问题,设计了基于记忆网络结构的情感记忆体,用来存储与表征数量是用户行为数倍的用户情感;在一定程度上解决了情感信息量过大而产生的表征局限性问题,并为多类情感关系的挖掘与结果解释做准备。

(2) 为了充分挖掘多类别的情感序列间的关系,基于情感记忆体提出了两类约束机制:情感自我约束和情感相互约束。这两种机制以条件概率的形式对同类别与其他类别的情感施加约束,从而隐式地捕获了多类别情感序列间的潜在关联,最终服务于行为序列挖掘来完成推荐。

(3) 为了解决序列情感贡献的可解释问题,将多类别情感序列的关联表征为注意力,并存储在注意力记忆体中。这种设计使模型在训练结束时可以直接展示记忆体,从而实现可解释功能。

本文第 2 节对与本研究相关的工作进行介绍;第 3 节从整体和细节两个层面介绍 SMC;第 4 节验证模型各方面的性能与表现;最后总结全文并展望未来。

## 2 相关工作

序列推荐通过捕捉用户的时序行为进行建模,而基于情感的推荐则更关注用户的主观因素以此完成偏好挖掘。本节首先介绍序列推荐和基于情感的推荐的相关工作,进一步分析两者的区别与联系,并在最后的小节介绍基于情感的序列推荐的最新研究工作。

### 2.1 基于记忆与注意力的序列推荐

在序列推荐的研究早期,大部分学者利用马尔可夫链(Markov chain)的原理来实现时序预测,例如,FPMC(Factorizing Personalized Markov Chains)<sup>[13]</sup>以分解模型为主体结合

马尔可夫链的结构完成下一个物品的推荐;HRM(Hierarchical Representation Model)<sup>[14]</sup>在马尔可夫链的基础上提出用嵌入向量建立层次表征模型来聚集序列中的对象。这类方法的局限在于下一个物品的预测过于依赖上一个(最近)物品,而对用户的长期历史行为序列进行建模的能力有限。循环神经网络(Recurrent Neural Network, RNN)的应用使得模型可以对更长的用户行为序列进行建模,例如,GRU4Rec<sup>[3]</sup>灵活地把不同长度的用户行为序列拼接在一起充分适应 RNN 要求输入为等长序列的性质。RNN 相比马尔可夫链的优势在于其使用了小型的记忆单元来记录历史模式,从而能在更多的历史信息中挖掘它们彼此间的联系<sup>[4]</sup>。然而,RNN 的小型记忆单元在需要存储大量的历史信息时具有局限性。为此,基于 RNN 的记忆网络(MemNN)<sup>[15]</sup>通过引入整块记忆体来增加模型的知识存储量并提升性能。例如,Ebesu 等<sup>[16]</sup>以记忆网络为载体,利用邻域信息提出了一个通用的协同记忆框架;在序列推荐方面,Chen 等<sup>[17]</sup>使用记忆网络存储用户的历史反馈记录,从物品与特征两个角度对记忆进行读写,更直观地体现了序列中的不同物品对偏好的影响;基于知识的记忆网络<sup>[6]</sup>则能够在挖掘用户连续行为的同时,利用键-值对(Key-Value)表达并捕捉属性级别的用户偏好,显著地提升了整体性能。

近年来,随着时序感知研究的发展<sup>[18]</sup>,注意力机制(Attention mechanism)<sup>[11]</sup>在推荐模型中得到了很好的应用。例如,利用注意力机制挖掘异质网络表征向量之间的关系<sup>[19]</sup>来提升模型预测精度。在众多注意力方法中,自注意力机制(Self-attention mechanism)在处理用户行为序列方面的优势尤为明显。Kang 等提出 SASRec<sup>[5]</sup>,将多头自注意力直接用于序列推荐并取得了比马尔可夫链和 RNN 两类方法都好的性能。FDSA (Feature-level Deeper Self-Attention Network)<sup>[20]</sup>则进一步发挥了自注意力的优势,在物品特征层面捕获用户偏好来配合行为序列完成推荐。本文的模型将与 SASRec 和 FDSA 这两个先进的方法作比较,并采用消融学习法来分析情感因素对序列推荐的影响作用。

### 2.2 基于文本情感的推荐

在推荐系统中,用户的海量文本评论是情感(Sentiment)获取的直接和主要来源;同时,基于文本评论的情感分析(Sentiment analysis)<sup>[21]</sup>也是对推荐模型的一种辅助和加强。例如,通过融合用户文本情感与相似度,可以高效地挖掘偏好并实现特定领域的推荐<sup>[22]</sup>。预先对评论文本进行情感分析可以清晰地知道用户的情感倾向,有利于后期针对用户偏好的预测结果做辅助解释。文本情感分析中比较常用的工具是 Stanford 的 CoreNLP<sup>[23]</sup>,它可以从评论中抽取一个总体的情感分数和 Very Positive, Positive, Neutral, Negative, Very Negative 这 5 个极性的分数。一些模型则使用自己提出的方法完成情感极性分析,例如,Pappas 等提出了 SANN(Sentiment-Aware Nearest Neighbor)模型<sup>[7]</sup>,该模型在情感分数和用户评分之间建立映射进而完成情感与评分的互补;Meng 等<sup>[24]</sup>从全局和局部两个角度对评论中的情感进行了正面和负面的分析,以此来推断用户的偏好。Xu 等<sup>[8]</sup>则把情感当作用户的意见偏移进行深入的挖掘,并最终与用户评分一起完成偏好预测。该方法的先进之处在于其把情感当作向量来处理,从而改进了以往只用极性分数来表示的局限性。情感

向量化的另一种处理方式是先将评论向量化进而学习出全局情感,再用编码好的情感向量来引导推荐<sup>[25]</sup>,从而提高训练效率并节省存储空间。这些已有的基于情感的推荐极少考虑到时间因素对情感的影响,以下将介绍时序情感与序列推荐的相关研究。

### 2.3 基于文本情感的推荐

序列推荐考虑的就是用户连续行为之间的关系,其中,情感的时序关系是一个需要被考虑的重要因素。例如, Li 等<sup>[9]</sup>首先从物品的角度出发,对物品的某几个重要属性(方面)分时间段建模;再配合用户在这些物品属性上的情感注意力,从物品和用户两个层面来融合完成偏好挖掘。与传统的基于时序情感的推荐不同,序列推荐中的用户情感也跟行为一样具有时序特性,而现有的基于序列推荐的研究<sup>[2]</sup>只有极少的模型对情感序列进行显式地建模。例如, Zheng 等<sup>[10]</sup>提出的 SGS 序列推荐模型(Sentiment-Guided Sequential recommender)采用双通道混合策略完成行为序列和情感序列的建模。SGS 的主通道采用情感引导的用户行为模式进行偏好挖掘;另一个通道则由稀疏注意力机制<sup>[12]</sup>单独处理情感序列;最终双通道融合之后输出用户偏好。该工作第一次将情感序列显式地单独建模,也是第一个基于时序情感的完整序列推荐模型。然而,注意力机制虽然可以捕捉单个情感序列的前后情感变化关系,但情感类型的多样化(例如 Stanford 的 CoreNLP 可以产生 5 类情感)性质使得注意力在捕获多个情感间的联系时存在局限性。本文的研究拟通过记忆网络的存储机制来存储多样化的情感,并以约束机制来弥补注意力机制的上述缺陷,达到完善情感序列建模的目的。

## 3 基于情感记忆约束的序列推荐模型

3.1 节首先给出基于情感的序列推荐的规范化描述;3.2 节介绍基于情感记忆约束的整体模型框架;3.3 节介绍模型的实现细节。

### 3.1 基于情感的序列推荐规范化描述

在一般的序列推荐中,模型会根据用户的历史行为来预测该用户的下一个行为。其中,用户的历史行为定义为  $\mathcal{I}^u = (i_1^u, i_2^u, \dots, i_{|\mathcal{I}^u|}^u)$ 。由于用户行为作用的对象一般是物品,所以  $\mathcal{I}^u$  可以被具体化为用户  $u$  交互过的  $|\mathcal{I}^u|$  个物品组成的有序序列,该序列按时间先后排序。例如,在某个时刻  $t$ , 用户  $u$  的行为可表示为物品  $i_t^u$ 。由 1.2 节的基于情感推荐的相关工作可知,用户在  $t$  时刻的行为  $i_t^u$  会附带几类情感,简单的有 Positive, Neutral, Negative 这 3 类。设用户发生行为  $i_t^u$  时有  $M$  类情感,定义  $S_t^u = (s_1^t, s_2^t, \dots, s_M^t)^u$  为用户  $u$  在  $t$  时刻的情感状态。称  $s_1^t, s_2^t, \dots, s_M^t$  为情感因子,每个因子对应其中的一类情感,例如,  $s_1^t$  对应的是 Positive。每类情感因子的值均以概率的形式呈现,比如  $s_1^t = 0.68$ ;而  $M$  类情感因子的值的总和为 1。由上述定义,基于情感的序列推荐可规范化描述为:给定用户  $u$  的历史行为和情感状态序列  $((i_1^u, S_1^u), (i_2^u, S_2^u), \dots, (i_{|\mathcal{I}^u|}^u, S_{|\mathcal{I}^u|}^u))$ , 预测用户的下一个行为(例如她/他最可能交互的下一个物品)。其中,  $(i_t^u, S_t^u)$  被称为一个  $t$  时刻的(行为,情感)元组。为了方便地表示,在已知用户的情况下可以省略用户标识  $u$ , 则情感状态序列可简化表示为  $((i_1, S_1), (i_2, S_2), \dots, (i_n, S_n))$ 。以下将以  $n$  个(行为,情感)元组构成的序列为基础统一地介绍模型。

### 3.2 情感记忆约束的整体框架

由 3.1 节可知,基于情感的序列推荐在某个时刻  $t$  需要同时考虑(行为,情感)两种元素,来挖掘用户的时序偏好。这两种元素的性质有着很大的不同,  $t$  时刻的行为  $i_t^u$  是单个元素,而情感  $S_t^u = (s_1^t, s_2^t, \dots, s_M^t)^u$  则是一个集合。已有的 SGS 模型<sup>[10]</sup>在处理  $(i_t^u, S_t^u)$  时采用了双通道模式,在主通道中由情感  $S_t^u$  引导行为  $i_t^u$  产生自注意力来挖掘时序偏好;在纯情感通道中则用情感约束注意力机制完成对情感  $S_t^u$  的偏好挖掘。这种双注意力机制可以有效捕捉行为序列和情感序列的前后变化关系,但是它忽视了情感  $S_t^u$  是一个集合,其在  $t$  时刻包含的信息量要远大于行为  $i_t^u$  的信息。为了解决情感信息量过大而产生的表征局限性问题,我们采用并改进了记忆网络的结构来表征与存储情感,称之为情感记忆体。以情感记忆作为载体,本文提出了情感记忆可约束的序列推荐模型 SMC, 如图 1 所示。

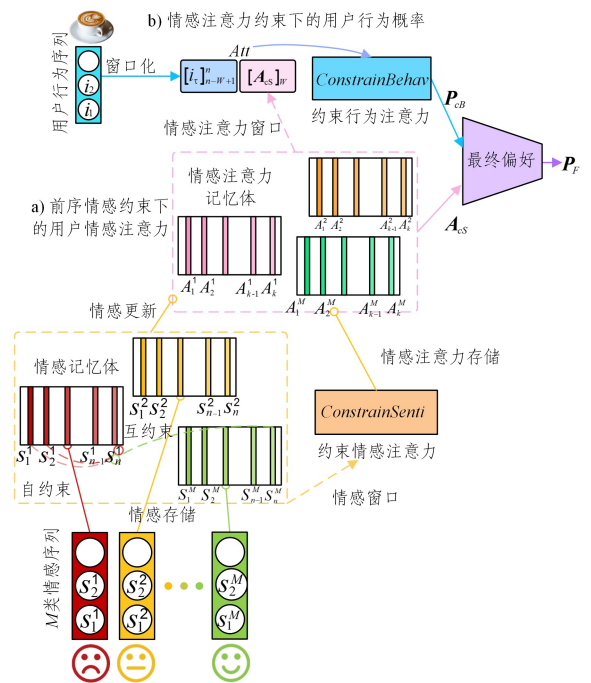


图 1 情感记忆可约束的序列推荐模型框架(电子版为彩图)

Fig. 1 Framework of sentiment memory-constrained sequential (SMC) recommender

以用户行为序列  $\{i_1, i_2, \dots, i_n\}$  为基准,图 1 以下标  $1, 2, \dots, n$  表示行为和对应情感的时间顺序。为了记录大量的情感序列信息,SMC 为每类情感分配了一个情感记忆体。例如为第  $m$  类情感分配记忆  $\{s_1^m, s_2^m, \dots, s_{n-1}^m, s_n^m\}$ , 其中  $s_n^m$  为第  $n$  个情感因子。与使用嵌入向量来表征行为序列不同,情感记忆体可以储存长期的变化的情感因子,这些长期的时序情感变化显然对用户决策具有重要的影响。为了刻画时序情感之间的相互关系以及它们对用户偏好的影响,本文提出了一种情感记忆变化可约束的机制。

具体地,某类情感对自身有自约束(Self-Constraint)的作用,这种作用体现在,该类情感的早期因子会随时间延续而影响到同类情感的后期因子。如图 1 中红色虚线所示的  $s_1^1, s_2^1$  会影响到后面的  $s_3^1$ , 即被雨打湿鞋产生的低落心情可能会从早上一直持续到中午。与自约束相比,某类情感对其他类情感的影响作用被称为互约束(Mutual-Constraint)。例如图 1

中绿色虚线表示正面类型的情感  $s_n^M$  对负面类型情感  $s_n^1$  的作用,即中午的时候听说同事要请吃饭感到很兴奋,从而缓和了上午的低落心情。

基于自约束和互约束,SMC对情感的处理更有弹性。具体地,本文设计了约束情感的注意力 ConstrainSenti 来表征当前情感在有限个前序情感影响下的变化。为了限定前序情感的个数,本文提出了滑动情感窗口机制来提供  $W$  个前序情感。由前序情感约束产生的情感注意力被存储在记忆体  $\mathbf{A}_{cs}$  中;同时,原有的情感记忆体也被更新。为了充分发挥情感建模对时序行为的作用,用户行为序列被窗口化为  $W$  个行为,在注意力  $[\mathbf{A}_{cs}]_W$  的约束下产生约束行为概率  $\mathbf{P}_{cb}$ 。情感注意力  $\mathbf{A}_{cs}$  和行为概率  $\mathbf{P}_{cb}$  共同作用产生最终偏好  $\mathbf{P}_F$ ,它表示用户产生第  $n$  个行为的概率。

### 3.3 SMC 模型实现细节

具备双约束机制的 SMC 在实现时,以记忆体作为表征的载体,然后用两类约束机制逐步更新与约束两种偏好的形成,最终完成序列偏好挖掘,下文逐一介绍相关细节。

#### 3.3.1 记忆体表征

与传统的嵌入向量表征不同,记忆体的表示与存储具有时序关系,我们将时序情感按顺序装入一个连续存储的空间,得到情感记忆体,第  $m$  类情感对应的记忆体定义如下:

$$S_{ENTI}M_{EMORY} \triangleq [\{s_1^m, s_2^m, \dots, s_{n-1}^m, s_n^m\}] \quad (1)$$

情感记忆体与嵌入向量是不同的存储结构,不仅在于情感记忆有记忆网络的基本功能,即能够进行多个记忆体间的交互,还在于情感记忆体存储的元素是时间上连续的情感向量。与情感记忆体具有相似结构的是情感注意力记忆体,它从情感注意力层中生成,定义如下:

$$A_{TT}M_{EMORY} \triangleq [\{A_1^m, A_2^m, \dots, A_{\tau-1}^m, A_{\tau}^m\}] \quad (2)$$

其中,情感注意力的时序  $\{1, 2, \dots, \tau-1, \tau\}$  由作用在情感时序上的注意力产生,其长度是多头注意力<sup>[11]</sup>的输出序列长度。在默认情况下,注意力的时序与原始情感的时序  $\{1, 2, \dots, n-1, n\}$  一致。

这两类记忆体是情感记忆约束机制的载体,也是 SMC 刻画时序情感之间联系的基础。

#### 3.3.2 情感记忆约束机制

情感记忆由情感序列构成,而情感序列是用户最终偏好形成的主观因素。由于本工作讨论的范畴是情感对行为的决定作用,并且  $M$  类情感的并集构成了某个特定用户的整体情感,因此,我们可以将最终偏好定义为该用户在这  $M$  类情感作用下产生第  $n$  个行为的概率:

$$\mathbf{P}_F = P(i_n) = \sum_{m=1}^M P(s_n^m, s_{1 \rightarrow n-1}^m) P(i_n | s_n^m, s_{1 \rightarrow n-1}^m) \quad (3)$$

其中,  $P(s_n^m, s_{1 \rightarrow n-1}^m)$  表示当前第  $m$  类情感  $s_n^m$  与前序情感  $s_{1 \rightarrow n-1}^m$  的联合概率,在第  $m$  类情感联合概率的作用下得到第  $n$  个行为产生的条件概率  $P(i_n | s_n^m, s_{1 \rightarrow n-1}^m)$ 。我们将联合概率细化为条件概率的形式:

$$P(s_n^m, s_{1 \rightarrow n-1}^m) = P(s_{1 \rightarrow n-1}^m) P(s_n^m | s_{1 \rightarrow n-1}^m) \quad (4)$$

由条件概率的形式可知第  $n$  个情感  $s_n^m$  实际上是受前  $n-1$  个情感  $\{s_1^m, s_2^m, \dots, s_{n-1}^m\}$  约束的,即前序情感是当前情感形成的条件。在式(1)中设计的记忆体由于保存了所有时序情感,因此可以方便地表示约束。式(4)中的时序情感都是同类型的(比如第  $m$  类),我们称这类情感记忆约束为自约束

(Self-Constraint)。相比之下,互约束(Mutual-Constraint)机制是另一类(第  $k$  类)前序情感对当前第  $n$  个情感  $s_n^m$  的约束,表示如下:

$$P(s_n^m, s_{1 \rightarrow n-1}^k) = P(s_{1 \rightarrow n-1}^k) P(s_n^m | s_{1 \rightarrow n-1}^k) \quad (5)$$

概率  $P(s_{1 \rightarrow n-1}^k)$  可以用前  $n-1$  个情感记忆  $\{s_1^k, s_2^k, \dots, s_{n-1}^k\}$  对应的向量来直接表征。在具体操作时,用滑动窗口来控制前序情感记忆的范围,并用  $W$  来表示窗口的大小。例如,我们用  $[s_j^k]_{n-W}^{n-1}$  表示宽度为  $W$  的第  $k$  类情感记忆窗口,序列范围从  $n-W$  开始到  $n-1$  结束,  $s_j^k$  就是记忆窗口中的第  $j$  个情感。因此,  $P(s_n^m | s_{1 \rightarrow n-1}^k)$  可以写成  $P(s_n^m | s_W^k)$ ,表示  $s_n^m$  在  $W$  个第  $k$  类前序情感影响下的概率。由于注意力机制中的查询序列可以通过相似度的方式影响当前序列,因此我们定义情感约束注意力来表征这种影响:

$$\begin{aligned} P(s_n^m | s_W^k) &= \text{ConstrainSenti}([\mathbf{s}_n^m]_W, [\mathbf{s}_j^k]_{n-W}^{n-1}) \\ &= \text{Att}([\mathbf{s}_j^k]_{n-W}^{n-1} \mathbf{E}^Q, [\mathbf{s}_n^m]_W \mathbf{E}^K, [\mathbf{s}_n^m]_W \mathbf{E}^V), W \geq 1 \end{aligned} \quad (6)$$

式(6)表示在前序情感窗口  $[s_j^k]_{n-W}^{n-1}$  作为查询的条件下,当前情感  $s_n^m$  的变化情况,  $\mathbf{E}^Q, \mathbf{E}^K, \mathbf{E}^V \in \mathbb{R}^{d \times d}$  是维度为  $d$  的序列情感向量对应的投影矩阵。为了方便注意力一对一的相似度计算,我们将  $s_n^m$  复制扩展为  $W$  个,即与窗口大小一致并表示为  $[\mathbf{s}_n^m]_W$ 。  $\text{Att}(\cdot)$  表示多头注意力机制,定义为:

$$\text{Att}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d}}\right) \mathbf{V} \quad (7)$$

由此,概率  $P(s_{1 \rightarrow n-1}^k)$  可以写为  $P(s_W^k)$ ,它与  $P(s_n^m | s_W^k)$  进行对应元素的乘法  $\odot$  即可得到式(5)中的约束情感概率的具体实现,我们用情感约束注意力来表示,并将其保存在记忆体  $\mathbf{A}_{cs}$  中:

$$\begin{aligned} \mathbf{A}_{cs} &= P(s_n^m, s_W^k) = P(s_W^k) P(s_n^m | s_W^k) \\ &= [s_j^k]_{n-W}^{n-1} \odot \text{ConstrainSenti}([\mathbf{s}_n^m]_W, [\mathbf{s}_j^k]_{n-W}^{n-1}) \end{aligned} \quad (8)$$

式(8)是两类约束机制的统一表征。特别地,当  $k=m$  时表示自约束机制,当  $k \neq m$  时则表示互约束机制。  $\mathbf{A}_{cs}$  代表纯情感的建模,它实现了多类别的情感序列间的关联挖掘,下文考虑约束行为概率。

#### 3.3.3 约束行为概率与最终偏好

由于情感与行为的序列类别不同,并且多类情感序列难以直接约束行为序列,因此我们首先借助第  $m$  类情感注意力记忆  $\mathbf{A}_{cs}^m$  完成对约束行为概率  $\mathbf{P}_{cb}$  的建模:

$$\begin{aligned} \mathbf{P}_{cb} &= P(i_n | s_n^m, s_W^k) \\ &= \text{ConstrainBehav}([\mathbf{A}_{cs}^m]_W, [i_{\tau}]_{n-W+1}^n) \\ &= \text{Att}([\mathbf{A}_{cs}^m]_W \mathbf{E}^Q, [i_{\tau}]_{n-W+1}^n \mathbf{E}^K, [i_{\tau}]_{n-W+1}^n \mathbf{E}^V), W \geq 1 \end{aligned} \quad (9)$$

从情感记忆约束生成的注意力记忆的窗口大小为  $W$ ,所以用符号  $[\mathbf{A}_{cs}]_W$  表示。  $[\mathbf{A}_{cs}]_W$  作为查询条件约束行为序列  $[i_{\tau}]_{n-W+1}^n$ ,所以行为序列的长度与记忆的长度大小一致,同为  $W$ 。  $i_{\tau}$  表示范围从第  $n-W+1$  个到第  $n$  个行为中的第  $\tau$  个行为。至此,结合式(3),最终偏好可以表示为:

$$\mathbf{P}_F = P(i_n) = \sum_{m=1}^M \mathbf{A}_{cs}^m \odot \mathbf{P}_{cb}^m \quad (10)$$

最终偏好  $\mathbf{P}_F$  定义的是  $M$  类情感共同作用下产生当前第  $n$  个行为的概率。与 SGS 对情感的简单拼接与叠加不同的是,本文模型中的注意力记忆  $\mathbf{A}_{cs}$  和行为概率  $\mathbf{P}_{cb}$  均实现了不同情感类别之间的隐式关联建模。在实验中,我们实现了

正面情感之间的互约束和负面情感间的互约束;并且比较了互约束与自约束的性能,从而更深入地探讨了两类约束机制对情感建模的影响。最后,我们通过对情感注意力记忆的可视化,实现了对情感变化的可解释分析,这种对情感的解释方法是已有研究未涉及的。

## 4 实验

实验使用4个公开可获取的数据集来评估本文模型,分别是选自Yelp Challenge<sup>1)</sup>的Restaurant和Bars,与选自Amazon<sup>2)</sup>的Baby和Videogames。4个数据集的(用户,物品)数量分别为:Restaurant(1 264, 37 352),Bars(1 263, 10 426),Baby(470 361, 64 421)和Videogames(613 076, 41 361)。在4个数据集中随机地抽取用户行为子序列,按照8:1:1的比例划分训练集、测试集、验证集;并将最长行为子序列的长度定为50。其中,Restaurant作用在物品上的用户平均行为最少,每个物品只有平均3.2个用户交互过;Videogames最多,每个物品有平均23.7个交互行为。在数量方面,Restaurant的行为总数是 $0.12 \times 10^6$ ;而Videogames则是 $0.97 \times 10^6$ 。我们在用户行为子序列上使用Stanford CoreNLP工具<sup>[23]</sup>来抽取对应的时序情感。这样就可以获得用户在某个时刻的行为对应的情感状态。该状态由5类情感因子构成,分别是Very Positive, Positive, Neutral, Negative, Very Negative。本文设计了方法比较、约束机制影响、和情感可解释3个子实验,从不同角度来评估SMC的性能与可解释能力。所有实验均采用5-折交叉验证。

### 4.1 方法比较

实验选用相关的序列推荐方法与情感类序列推荐模型与SMC进行比较,如表1所列。

表1 参与比较的序列推荐方法

Table 1 Sequential recommendation methods for comparison

Methods	Description
RNN	基于LSTM的循环神经网络
GRU4Rec <sup>[3]</sup>	基于改进GRU的序列推荐器
GRU4Senti <sup>[3]</sup>	GRU4Rec的改进版,将物品嵌入向量与情感嵌入向量拼接作为输入
SASRec <sup>[5]</sup>	基于多头自注意力机制的序列推荐器
CFSA <sup>[20]</sup>	考虑情感作为特征的基于双多头自注意力机制的先进序列推荐器
SGS <sup>[10]</sup>	情感引导的先进序列推荐器,同时使用了多头注意力与稀疏注意力
SMC-S	情感记忆可约束的序列推荐模型——自约束(Self-Constraint)版本
SMC-M	情感记忆可约束的序列推荐模型——互约束(Mutual-Constraint)版本

由于4个数据集大小不同,因此我们将小数据集(Restaurant, Bars)分为一组,大数据集(Baby, Videogames)分为另一组。小数据集的batch\_size设置为128,大数据集设置为256。同样地,小数据集的embedding\_dimension设置为20,大数据集对应设置为30。分开设置之后,我们统一使用Adam作为优化器,并将初始学习速率调为0.001。对于与多头自注意力相关的方法,即后面的5类方法,我们将head\_number和size\_per\_head两个参数进行了统一。大数据集使用

6个head\_number,小数据集使用5个;对应的size\_per\_head分别为5和4。由于SGS使用了稀疏注意力机制,所以在大数据集和小数据集上分别设置其稀疏率为5和3。SMC-S是情感自约束的版本,SMC-M在SMC-S的基础上增加了不同类情感间的互约束。SMC的两个版本都需要设置滑动窗口的大小,我们默认设置窗口大小为10。为了与SGS的评估指标保持一致,本文使用Hit与NDCG两种指标来评价性能,方法比较的实验结果如表2和表3所列。

表2 Hit@10 的比较实验结果

Table 2 Experimental results of Hit@10 by method comparison (单位:%)

Methods	Restaurant	Bars	Baby	Videogames
RNN	6.923	15.439	18.945	23.707
GRU4Rec	7.628	15.932	23.982	26.435
GRU4Senti	10.085	17.02	24.533	30.935
SASRec	14.394	32.427	56.862	54.734
CFSA	18.473	34.5	59.81	56.904
SGS	23.216	45.138	65.049	61.598
SMC-S	<u>24.236</u>	<u>46.412</u>	<u>66.529</u>	<u>62.993</u>
SMC-M	<b>24.928</b>	<b>47.065</b>	<b>66.776</b>	<b>63.27</b>

表3 NDCG@10 的比较实验结果

Table 3 Experimental results of NDCG@10 by method comparison (单位:%)

Methods	Restaurant	Bars	Baby	Videogames
RNN	2.627	6.065	9.197	10.099
GRU4Rec	2.804	6.39	10.164	11.037
GRU4Senti	3.656	7.817	11.378	12.125
SASRec	5.702	10.836	17.459	17.781
CFSA	7.288	11.475	19.633	19.361
SGS	9.325	14.647	22.176	22.317
SMC-S	<u>10.733</u>	<u>15.398</u>	<b>24.003</b>	<u>25.535</u>
SMC-M	<b>11.125</b>	<b>15.903</b>	<u>23.897</u>	<b>25.618</b>

表2和表3中加粗数据表示某个指标上的最好性能,下划线数据表示次优性能。可以看出,SMC-S和SMC-M在4个数据集上都取得了最佳的性能。其中,SMC-M在大部分指标上领先SMC-S,而SMC-S在Baby数据集的NDCG指标上占有优势。两个SMC方法的表现说明了增加情感记忆体对提升序列推荐的性能是有积极帮助的;并且,情感的互约束相对于情感的自约束效果更明显。以下将对两类约束进行更深入的分析。

### 4.2 约束机制的影响

自约束模型SMC-S表征的是同类前序情感对当前时刻情感的约束。互约束模型SMC-M则是在同类情感约束的前提下,增加了其他类情感的约束。在实现时,考虑到将全部不同类型的情感进行两两互约束会增加不必要的复杂度,所以只采用Very Positive和Very Negative这两类特点鲜明的情感对其他类情感进行约束。情感记忆是SMC-S与SMC-M实现约束的载体,可以用滑动窗口来控制大小。具体地,我们设置情感窗口的大小为1~20,观察两个方法在窗口大小变化下的连续性能表现。另外,实验以SGS为基线方法研究情感记忆对注意力的增益效果,并使用Hit@20和NDCG@20两个指标进行对比,实验结果如图2所示。

<sup>1)</sup> <https://www.yelp.com/dataset/challenge>

<sup>2)</sup> <http://jmcauley.ucsd.edu/data/amazon/>

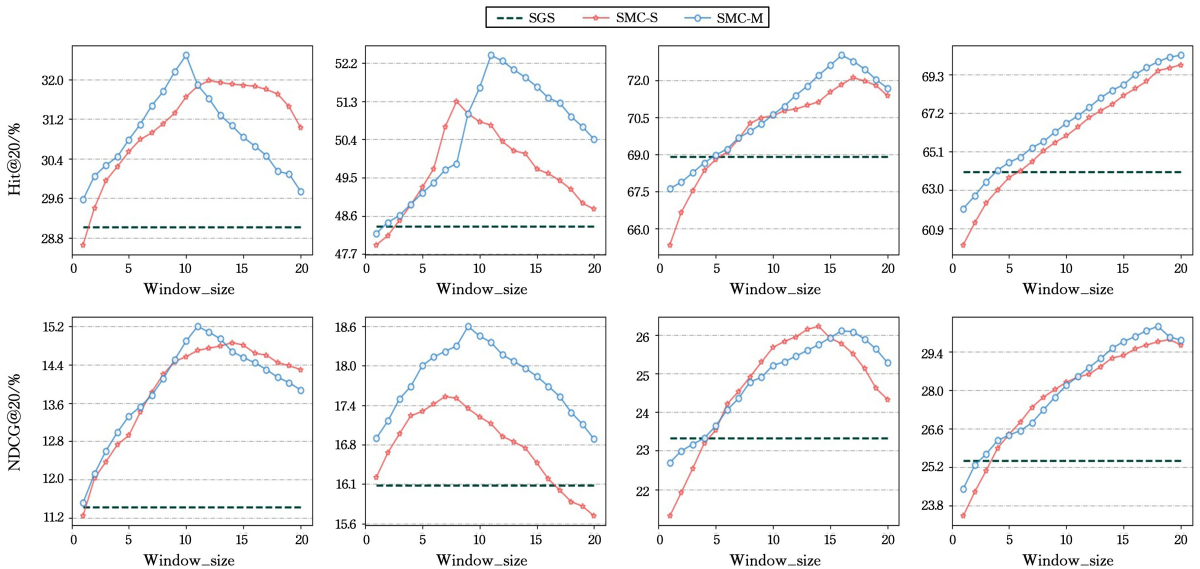


图 2 两类情感记忆约束机制的比较

Fig. 2 Comparison of two sentiment memory-constrained mechanism

从总体上看,两类 SMC 方法都比 SGS 有更显著的优势,说明情感记忆对基于情感自注意力的序列推荐模型是有明显增益效果的。并且,除了 Baby 数据集的 NDCG@20 指标上 SMC-S 比 SMC-M 更好之外,其他数据集上的指标都展示了互约束机制要优于自约束机制。从达到最佳性能的窗口大小来看,小数据集(Restaurant, Bars)的最佳窗口大小在 10 个左右;而大数据集(Baby, Videogames)要达到最好性能则需要更多记忆窗口,例如, Baby 数据集需要大约 15 个窗口。相比之下 Videogames 需要近 20 个窗口才能达到最优,随着窗口的增多, Hit@20 的表现还有进一步提高的可能。数据集的大小与窗口数大致呈正相关,这说明了记忆机制能够有效保存用户的历史情感偏好。进一步地,除了通过控制窗口大小来实现性能最优,本工作的另一个优势在于可以对情感记忆约束下的注意力进行解释。

### 4.3 时序情感可解释

在两类约束机制的作用下,情感注意力将随不同用户的不同行为而具备不同的表征。已有的工作大多数将注意力权重进行可视化来达到可解释的目的,但是,对单一注意力的可视化无法反映连续情感之间复杂的时间关联。我们通过将注意力装入记忆体来实现注意力的可视化,进而自然地完对情感时序变化的可解释功能。由 4.2 小节可观察到两类约束在 Bars 数据集上的性能表现区分比较明显,因此我们采用 Bars 数据集来解释情感注意力变化与模型表现之间的联系。我们随机抽取某个用户的行为序列,分别输入到 SMC-S 与 SMC-M 中进行预测,并记录两类约束作用下窗口大小为 10 与 20 时的整块情感注意力记忆体的值,最后可视化两类大小不同的注意力记忆体来观察它们的变化。我们对情感注意力中的每个记忆向量的各个维度值进行求和取平均并规范化到 [0, 1] 区间,用颜色表示它们的值,值越大颜色越深。特别地,暖色调表示偏正面的情感,而冷色调则表示偏负面的情感。图 3 和图 4 分别给出了 5 类情感注意力记忆体在约束机制下的可解释表征。

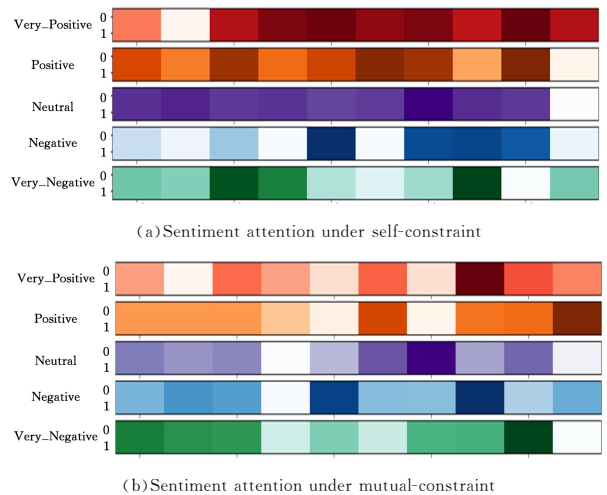


图 3 情感记忆体约束下的注意力可解释表征(窗口大小为 10)  
Fig. 3 Explainable attention representation under the sentiment constraint(window\_size=10)

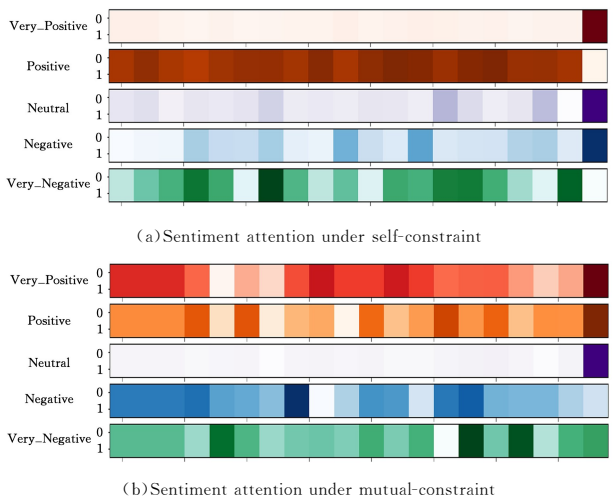


图 4 情感记忆体约束下的注意力可解释表征(窗口大小为 20)  
Fig. 4 Explainable attention representation under sentiment constraint(window\_size=20)

从图3可以看出,在自约束机制下,注意力记忆体的最后一个窗口(即最近时刻的情感注意力)呈现出较高的 Very\_Positive 倾向和中等的 Very\_Negative 倾向。对比互约束机制作用下的注意力,5类情感间的融合让整个记忆体变得更活跃,体现在颜色的变化趋势更加灵活。进一步观察发现,最后时刻的互约束注意力从两个极端(Very\_Positive 和 Very\_Negative)过渡到 Positive 和 Negative;并且,Very\_Positive 也保留了一定程度的值,所以从总体上看依然是偏正面的。可以看出互约束机制在恰当表征情感倾向的同时保留了情感类别的多样化表征,这也是 SMC-M 在 4.2 节中性能更优的原因。在 window\_size=20 的图 4 中,情感的互约束体现得更加直观与明显,例如,前两行直观地解释了相似类别情感 Very\_Positive 和 Positive 间的相互融合,但由于窗口太大,最后虽然能表现出情感的多样性,但是却没有 window\_size=10 时那么明显的情感倾向。这也解释了为什么在 Bars 数据集上设置 window\_size=20 时得到的性能要弱于 window\_size=10 时模型的性能。因此,我们可以直接从情感注意力记忆体中观察到用户的情感倾向,并通过比较记忆体推测出模型的相对性能。这是对深度模型可解释的一种尝试,这种表征与解释的方法在记录时序相关的多类复杂信息时是有应用价值的。

**结束语** 本工作面向基于情感的序列推荐任务,主要解决序列推荐中用户行为与用户情感的不对称问题,包括性质不同与信息量差异大两方面。我们设计了情感记忆体并进一步提出了情感注意力记忆体来解决这两个子问题。一方面,记忆网络的结构有助于存储与表征大量的情感信息;另一方面,情感记忆体可以借助注意力机制完成序列建模,从而使行为序列和情感序列性质不同的矛盾得到统一解决。本工作提出的约束机制对多类别情感的相互作用与辅助行为建模起到了关键的作用。基于记忆的约束机制既保证了大量的情感信息能被有效利用,又保证了这些情感信息对偏好预测的贡献能被记录与表征,为后续的时序情感可解释奠定了基础。本文方法不仅提升了原有先进方法的性能,而且首次做到了时序情感的可解释。

本文模型是面向基于情感的序列推荐任务的。实际上,许多基于用户时序主观因素(比如情绪、生理信号等)都可以采用这个框架来建模,因此,本文方法是具有可扩展性的。在后续的工作中,我们将采集与用户有关的时序主观数据,提出一个更通用的方法对用户的所有主观因素进行建模。针对不同类型的时序主观信息,我们拟采用不同粒度的时间建模方法;在融合多类主观因素方面,考虑借助先进的图神经网络在结构上的优势来捕捉与融合多种因素的潜在关联。在未来的研究中,我们仍然会以对用户主观因素的建模为重点,这是未来智能推荐系统的一个趋势。具体地,推荐系统从人机交互中萌芽,在发展过程中应用了许多人工智能的先进方法(比如深度神经网络建模),但它的最终目的仍然是考虑用户感受并为其服务。因此,以用户为中心进行主观建模是推荐系统未来一个重要发展趋势。

## 参考文献

- [1] ZHENG L,ZHU F X,YAO X. Recommendation rating prediction based on attribute boosting with partial sampling[J]. Chinese Journal of Computers,2016,39(8):1501-1514.
- [2] WANG S,HU L,WANG Y,et al. Sequential Recommender Systems:Challenges,Progress and Prospects[C]// Proceedings of the 28th International Joint Conference on Artificial Intelligence(IJCAI'19). 2019:6332-6338.
- [3] HIDASI B,KARATZOGLOU A,BALTRUNAS L,et al. Session-based Recommendations with Recurrent Neural Networks [C]//Proceedings of the 4th International Conference on Learning Representations(ICLR '16). 2016:1-10.
- [4] TAN Y K,XU X,LIU Y. Improved Recurrent Neural Networks for Session-based Recommendations[C]//Proceedings of the 1st Workshop on Deep Learning for Recommender Systems(DLRS'16). 2016:17-22.
- [5] KANG W,MCAULEY J. Self-Attentive Sequential Recommendation[C]//Proceedings of the 2018 IEEE International Conference on Data Mining(ICDM'18). 2018:197-206.
- [6] HUANG J,ZHAO W X,DOU H,et al. Improving sequential recommendation with knowledge-enhanced memory networks [C]//Proceedings of the 41st International ACM SIGIR Conference on Research & Development in Information Retrieval(SIGIR'18). 2018:505-514.
- [7] PAPPAS N,POPESCU-BELIS A. Adaptive sentiment-aware one-class collaborative filtering[J]. Expert Systems with Applications,2016,43(1):23-41.
- [8] XU Y,YANG Y,HAN J,et al. NeuO:Exploiting the sentimental bias between ratings and reviews with neural networks. Neural Networks,2019,111(3):77-88.
- [9] LI G,CHEN Q,ZHENG B,et al. Time-aspect-sentiment Recommendation Models Based on Novel Similarity Measure Methods[J]. ACM Transactions on the Web,2020,14(2):1-26.
- [10] ZHENG L,GUO N,CHEN W,et al. Sentiment-Guided Sequential Recommendation[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research & Development in Information Retrieval(SIGIR'20). 2020:1957-1960.
- [11] VASWANI A,SHAZEER N,PARMAR N,et al. Attention is All you Need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS'17). 2017:6000-6010.
- [12] CHILD R,GRAY S,RADFORD A,et al. Generating Long Sequences with Sparse Transformers[J]. arXiv:1904.10509,2019.
- [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(WWW'10). 2010:811-820.
- [14] WANG P,GUO J,LAN Y,et al. Learning hierarchical representation model for next basket recommendation[C]//Proceedings of the 38th International ACM SIGIR Conference on Research & Development in Information Retrieval (SIGIR'15). 2015:403-412.

- [15] SUKHAATAR S, SZLAM A, WESTON J, et al. End-to-end memory networks[C]// Proceedings of the 28th International Conference on Neural Information Processing Systems-Volume 2(NIPS'15). 2015:2440-2448.
- [16] EBESU T, SHEN B, FANG Y. Collaborative memory network for recommendation systems[C]// Proceedings of the 41st International ACM SIGIR Conference on Research & Development in Information Retrieval(SIGIR'18). 2018:515-524.
- [17] CHEN X, XU H, ZHANG Y, et al. Sequential recommendation with user memory networks[C]// Proceedings of the 11th ACM International Conference on Web Search and Data Mining(WSDM'18). 2018:108-116.
- [18] WANG Y G, JIANG C C, FENG X N, et al. Time Aware Point-of-interest Recommendation [J]. Computer Science, 2021, 48(9):43-49.
- [19] ZHAO J L, ZHAO Z Y. Recommendation Algorithm Based on Heterogeneous Information Network Embedding and Attention Neural Network[J]. Computer Science, 2021, 48(8):72-79.
- [20] ZHANG T, ZHAO P, LIU Y, et al. Feature-level Deeper Self-Attention Network for Sequential Recommendation[C]// Proceedings of the 28th International Joint Conference on Artificial Intelligence(IJCAI'19). 2019:4320-4326.
- [21] CHEN Q, CHE M M, GUO X, et al. Recurrent Convolution Attention Model for Sentiment Classification [J]. Computer Science, 2021, 48(2):245-249.
- [22] SUN Z Q, LUO Y L, ZHENG X Y, et al. Intelligent Travel Route Recommendation Method Integrating User Emotion and Similarity[J]. Computer Science, 2021, 48(S1):226-230.
- [23] CHRISTOPHER M, MIHAI S, JOHN B, et al. The Stanford CoreNLP Natural Language Processing Toolkit[C]// Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics; System Demonstrations(ACL'14). 2014:55-60.
- [24] MENG X, WANG S, LIU H Z, et al. Exploiting Emotion on Reviews for Recommender Systems[C]// Proceedings of the 32nd AAAI Conference on Artificial Intelligence(AAAI'18). 2018:3788-3795.
- [25] HYUN D, PARK C, YANG M C, et al. Review Sentiment-Guided Scalable Deep Recommender System[C]// Proceedings of the 41st International ACM SIGIR Conference on Research & Development in Information Retrieval(SIGIR'18). 2018:965-968.



**ZHENG Lin**, born in 1984, Ph.D, Lecturer, master supervisor, is a member of ACM and CCF. His main research interests include explainable deep learning and recommender systems.