

基于矩阵与混合机制双流长短期记忆网络的终身长序列推荐方法

孙文奇^{1,3)} 谢若冰²⁾ 张君杰^{1,3)} 赵鑫^{1,3)} 康战辉²⁾ 文继荣^{1,3)}

¹⁾(中国人民大学高瓴人工智能学院 北京 100872)

²⁾(腾讯公司 北京 100193)

³⁾(中国人民大学大数据管理与分析方法研究北京市重点实验室 北京 100872)

摘 要 终身长序列推荐(Lifelong Sequential Recommendation, LSR)旨在建模用户在互联网在线系统使用过程中所累积的长期行为序列,用以预测用户潜在感兴趣的可能会产生交互的物品。相比基于短期行为或静态偏好的传统序列推荐,终身长序列推荐试图理解和预测用户在长时间跨度内的行为模式和偏好演变,从而发掘用户的长期兴趣偏好。受自然语言处理领域中类似的序列建模任务的启发,以GRU4Rec、SASRec等为代表的模型成功将循环神经网络和自注意力机制用于序列推荐任务,并得到了广泛的应用。然而,现有序列推荐方法直接应用于终身长序列任务时会表现出固有的局限性:基于循环神经网络的方法容易遭遇梯度消失问题且记忆容量受限;基于Transformer的方法在处理长序列时面临二次复杂度和高内存消耗的挑战;而基于状态空间模型的方法则往往难以在短期偏好建模与长期依赖捕捉之间取得平衡。这些局限性共同促使研究者探索面向终身长序列推荐的新型模型结构。随着最近新型长短期记忆网络模型xLSTM的提出并在多项自然语言处理任务上得到验证,循环神经网络在处理长序列任务的能力再次引起了广泛的关注。相比于传统LSTM,xLSTM通过引入矩阵记忆和指数门控等机制,显著增强了记忆能力,提升了并行处理效率,优化了门控机制,使其在处理长序列数据时更加高效,性能表现与当前先进模型相媲美。基于此,本文实现并验证了多种循环神经网络的变种模型在终身长序列推荐任务上的能力,并提出了一种基于矩阵与混合机制双流长短期记忆网络、采用门控网络进行长短期记忆自适应融合的终身长序列推荐方法,称为xLSTM-LSR,这是首次探索矩阵与混合机制长短期记忆网络在终身长序列推荐任务上的工作。xLSTM-LSR首先利用矩阵长短期记忆网络模块建模用户的长期兴趣偏好,并通过混合长短期记忆网络模块捕捉用户的短期兴趣偏好;随后,引入门控网络以自适应地融合用户的长短期偏好,并进一步设计了面向长短期偏好融合的对比学习策略,以增强融合表示的有效性与判别性。我们在四个大规模公开数据集上进行详尽的实验和分析,实验结果表明,xLSTM-LSR可有效提升终身长序列推荐的性能和效率。我们将本文提出方法以及实现的多种基于循环神经网络变种的推荐方法的代码公开发布在<https://github.com/RUCAIBox/xLSTM-LSR>。

关键词 用户长期和短期偏好建模;终身长序列推荐;矩阵长短期记忆网络;混合长短期记忆网络

中图法分类号 TP18

DOI号 10.11897/SP.J.1016.2025.02789

A Method of Lifelong Sequential Recommendation Based on Matrix and Mixing Dual-Flow Long Short-Term Memory Networks

SUN Wen-Qi^{1,3)} XIE Ruo-Bing²⁾ ZHANG Jun-Jie^{1,3)} ZHAO Xin^{1,3)} KANG Zhan-Hui²⁾ WEN Ji-Rong^{1,3)}

¹⁾(Gaoling School of Artificial Intelligence, Renmin University of China, Beijing 100872)

²⁾(Tencent Inc., Beijing 100193)

³⁾(Beijing Key Laboratory of Big Data Management and Analysis Methods, Renmin University of China, Beijing 100872)

Abstract Lifelong sequential recommendation (LSR) aims to learn long-term behavior sequence

收稿日期:2024-10-14;在线发布日期:2025-09-11。本课题得到国家自然科学基金优秀青年科学基金项目(62222215)、中国科协青年人才托举工程(2023QNRC001)资助。孙文奇,博士研究生,主要研究领域为推荐系统、高效机器学习和大模型。E-mail:wenqisun@ruc.edu.cn。谢若冰,硕士,研究员,主要研究领域为大模型、信息检索和自然语言处理。张君杰,硕士研究生,主要研究领域为推荐系统和大模型。赵鑫(通信作者),博士,教授,中国计算机学会(CCF)杰出会员,主要研究领域为信息检索、自然语言处理和大模型。E-mail:batmanfly@gmail.com。康战辉,学士,研究员,主要研究领域为大模型和多模态。文继荣,博士,教授,主要研究领域为互联网大数据管理、信息检索和大模型。

patterns in chronological order accumulated by users during their utilization within online systems on the Internet. Compared to conventional sequential recommendation, which focus on short-term behaviors or static preferences, LSR attempts to understand and predict the evolution of users' behavior patterns and preferences over extended periods, thereby discovering users' long-term preferences. Inspired by similar sequence modeling tasks in natural language processing, sequential recommendation models such as GRU4Rec and SASRec have successfully adapted Recurrent Neural Networks (RNNs) and self-attention mechanisms to sequential recommendation tasks, achieving significant success. However, existing approaches exhibit inherent limitations when applied to lifelong sequences: RNN-based methods suffer from vanishing gradients and limited memory capacity, Transformer-based models face quadratic complexity and high memory consumption with long sequences, and state space models often struggle to balance short-term preference modeling with long-term dependency capture. These limitations motivate the search for new architectures tailored to lifelong sequential recommendation. The recent introduction of the extended long short-term memory network model (xLSTM) and its validation across various natural language processing tasks have once again drawn widespread attention to the capability of RNNs in handling long sequence tasks. Compared to conventional LSTM, xLSTM significantly enhances memory capacity through the introduction of matrix memory and exponential gating mechanisms. Additionally, it improves parallel processing efficiency and optimizes the gating mechanism, enabling more effective handling of long-sequence data. As a result, xLSTM achieves performance comparable to state-of-the-art models. To this end, we are motivated to explore the potential application of xLSTM in lifelong sequential recommendation. We implement multiple variants of RNNs and evaluate their capabilities in LSR tasks, and propose a LSR method based on matrix and mixing dual-flow long short-term memory (LSTM) networks, adopting a gating network for the adaptive fusion of long- and short-term preferences, called xLSTM-LSR. This represents the first exploration of the matrix and mixing long short-term memory networks in LSR tasks. xLSTM-LSR first leverages a matrix-based long short-term memory module to model users' long-term preferences, while employing a mixing-based LSTM module to capture their short-term interests. Subsequently, a gating network is introduced to adaptively fuse long- and short-term preferences, and a contrastive learning strategy is further incorporated to enhance both the effectiveness and the discriminability of the fused representations. We conducted extensive experiments and analyses on four public datasets, and the experimental results demonstrate that xLSTM-LSR consistently outperforms baseline methods.

Keywords user long-term and short-term preference modeling; lifelong sequential recommendation; matrix-based LSTM; mixing-based LSTM

1 引 言

据中国互联网络信息中心 (China Internet Network Information Center) 发布的《第 55 次中国互联网络发展状况统计报告》^[1]显示,截至 2024 年 12 月,我国短视频用户规模达 10.40 亿人,网民使用率为 93.8%。短视频作为中国网民使用率最高的互联网应用之一,其用户体验对于短视频平台持续

吸引和保持用户活跃度至关重要。推荐算法作为短视频平台提高用户活跃度和观看时长的核心技术之一,其主要目标是通过建模用户兴趣偏好来向用户提供最具吸引力的短视频,从而对平台的可持续发展发挥关键作用。具体而言,推荐算法通过深入分析用户行为和偏好,智能地筛选和推送内容,不仅极大地丰富了用户的观看体验,也促进了内容创作者与观众之间的有效连接。此外,推荐算法的精准匹配能力,有助于短视频平台实现广告和商品的个性

化营销,从而为平台带来可观的商业价值。

序列推荐(Sequential Recommendation, SR)方法是推荐算法领域中的一个重要分支,旨在从用户的按照时间顺序的交互中建模用户的兴趣偏好,用以学习用户的潜在兴趣以及预测下一个用户可能交互的物品。现有大多数序列推荐方法主要关注于学习用户的短期偏好,因其往往能够直接反映用户当前的兴趣和需求。早期基于神经网络的序列推荐方法主要分为基于循环神经网络^[2-3](Recurrent Neural Network, RNN)和基于卷积神经网络^[4-5](Convolutional Neural Networks, CNN)。例如,GRU4Rec^[6]利用门控循环神经单元对用户行为序列进行编码。近年来,基于Transformer模型^[7]的序列推荐方法因其强大的序列建模能力而成为最先进的方法^[8-9]。最近,随着状态空间模型^[10]的快速发展,基于选择性状态空间模型的序列推荐方法(例如Mamba4Rec^[11]和RecMamba^[12])被引入以提高序列推荐的效率。

虽然现有的序列推荐方法在电商平台、新闻推荐等在线服务中得到广泛应用,但随着短视频平台的快速发展和用户行为的高动态性,尤其是用户观看短视频数量的快速增长^[13](即用户观看的短视频按照时间顺序形成用户行为序列),为序列推荐方法的研究带来了新的挑战。伴随着用户行为数据的爆炸性增长,有效处理和分析越来越长的用户行为序列以提供准确及时的推荐,受到了越来越多推荐系统领域研究者的关注,此问题称之为终身长序列推荐^[14]。然而,直接将现有序列推荐方法应用在终身长序列推荐任务上会不同程度地存在局限性。例如,基于Transformer模型的SASRec^[8]擅长建模用户的短期兴趣偏好,但在建模终身长序列时遇到效率挑战,因为自注意力输入长度的二次复杂性导致巨大的内存需求;基于状态空间模型的Mamba4Rec擅长以高效率捕捉长期的用户行为依赖,但在挖掘用户短期兴趣偏好方面性能欠佳;基于门控循环神经单元的GRU4Rec在建模终身长序列时会面临信息遗忘和循环神经网络固有的梯度消失问题。另一条研究主线聚焦长行为序列建模用于点击率预估任务,主要有基于记忆增强网络的方法^[15]和基于检索的方法^[16-17],例如,基于记忆增强网络的MIMN^[15]借鉴记忆网络的思想,解决用户行为序列长度较长时的存储和延迟问题,能够处理长达1k长度的用户行为序列。基于检索的ETA通过相似度算法^[16]实现高效检索,结合注意力机制进行端到端训练,显著降低

了训练和推理成本,提升了点击率预估任务的效果。

随着最近新型长短期记忆网络xLSTM^[18-19]在自然语言处理领域中提出,循环神经网络再次引起了研究社区的广泛关注。相比于传统长短期记忆网络^[20](Long Short-Term Memory, LSTM),xLSTM引入了矩阵记忆与稳定化指数门控,显著增强了记忆容量,提升了并行处理效率,优化了门控机制,在处理长序列时拥有更好的性能、效率和可扩展性,性能表现与当前先进模型相媲美。循环神经网络天然适用于序列推荐任务,与传统LSTM结构相比,xLSTM具有更强的长期依赖建模能力,使得其在序列推荐任务上能够更有效地捕捉用户的长期行为偏好,从而提升推荐性能。然而,序列推荐任务虽然与自然语言处理领域中的语言任务存在一定的相似性,但也存在一些显著的差异,例如,用户序列相邻行为之间可能不存在过多的相关性,同时可能呈现出多样性的特点。因此,若直接沿用xLSTM的层堆叠方式并将其应用于序列推荐任务场景,可能难以达到理想的性能表现,并且在模型效率层面亦未必能够确保取得理想成效。在推荐系统中,用户的短期兴趣偏好是序列推荐算法需要考虑的重要因素,用户的长期兴趣偏好同样是一个不可忽视的因素。为此,为了能够同时有效学习到用户的长期偏好和短期偏好,本文提出了基于矩阵与混合机制双流长短期记忆网络的终身长序列推荐方法xLSTM-LSR,分别采用矩阵长短期记忆网络学习用户的长期偏好,采用混合长短期记忆网络学习用户的短期偏好,而后采用门控网络进行长期偏好和短期偏好的自适应融合,并进一步设计了面向长短期偏好融合的对比如学习策略,将xLSTM的能力整合到我们的终身长序列推荐方法框架中。xLSTM-LSR方法包括五个模块:(1)物品嵌入表示层:将给定物品列表中的各物品进行物品嵌入表示学习;(2)基于矩阵长短期记忆网络用户的长期偏好学习模块:通过矩阵长短期记忆网络学习各用户按时间顺序排列的行为数据,从而形成各用户的潜在长期偏好表示;(3)基于混合长短期记忆网络用户的短期偏好学习模块:通过混合长短期记忆网络学习各用户近期按时间顺序排列的某个长度范围的行为数据,从而形成各用户的潜在短期偏好表示;(4)基于门控网络的长期偏好和短期偏好自适应融合模块:通过门控网络自适应学习不同数据集上长期偏好和短期偏好的占比,并对长短期偏好进行融合;(5)面向长短期偏好融合的对比如学习策略:通过面向长短期融合的对

比学习损失作为辅助监督信号,增强融合表示的判别能力与个性化特征表达能力。

本文在序列推荐数据集“MovieLens”和“AmazonReview”^[21]及终身长序列推荐数据集“LFM-1b”^[22]和“KuaiRand”^[23]上分别进行了实验。实验表明 xLSTM-LSR 在推荐性能方面优于已有的基线方法,同时兼顾了效率和可扩展性,证明了矩阵长短期记忆网络和混合长短期记忆网络在终身长序列推荐任务上的有效性。

本文的主要贡献包括:

(1) 本文将新型长短期记忆网络 xLSTM 引入推荐系统领域,这是首次探索 xLSTM 在终身长序列推荐任务上的应用。针对终身长序列推荐任务的特点,本文对 xLSTM 的层堆叠方式进行了一系列改进使其能够更高效地适配推荐任务。

(2) 本文提出了基于矩阵与混合机制双流长短期记忆网络的终身长序列推荐方法 xLSTM-LSR,通过精细设计的模型结构,xLSTM-LSR 能够高效建模用户的长期偏好和短期偏好,从而能够更精准地预测用户的潜在兴趣。

(3) xLSTM-LSR 采用矩阵和混合长短期记忆网络以双流方式分别学习用户的长期和短期偏好,而后采用门控网络自适应融合长期偏好和短期偏好,并进一步设计了面向长短期偏好融合的对比如学习策略用以增强融合表示的有效性与判别性,从而实现更加精准的推荐。实验结果表明,xLSTM-LSR 在多个数据集上超过了现有广泛使用的序列推荐基线方法,不仅提升了排序和召回能力,还兼具计算效率和可扩展性。

(4) 实现了多个基于循环神经网络变种的推荐方法并公开发布了代码,以便推荐系统领域研究者进一步探究基于循环神经网络的终身长序列推荐方法。实验结果表明,矩阵与混合记忆有效提升了推荐性能,稳定化指数门控在一定程度上缓解了传统长短期记忆网络的长期依赖遗忘问题。基于矩阵记忆与混合记忆的长短期记忆网络模型相比传统循环神经网络模型在推荐任务上具有显著优势。

本文组织结构如下:本节介绍和讨论全文背景;第2节介绍本文的相关工作;第3节介绍任务定义、xLSTM 在推荐任务上的适用性分析和研究动机;第4节介绍 xLSTM-LSR 方法的具体模型结构,包括基于矩阵长短期记忆网络的长期偏好建模、基于混合长短期记忆网络的短期偏好建模、基于门控网络的长短期偏好融合和面向长短期偏好融合的对比如

学习策略;第5节介绍实验,包括数据集、实验设置、实验结果与分析;第6节对全文内容进行总结并对未来工作进行展望。

2 相关工作

2.1 终身长序列推荐

序列推荐任务旨在从用户的按照时间顺序的交互中建模用户的兴趣偏好,用以学习用户的潜在兴趣以及预测下一个用户可能交互的物品^[24-26]。早期的序列推荐研究使用马尔可夫链来建模用户交互序列^[27]。随着深度学习的发展,基于神经网络的序列推荐方法主要分为基于循环神经网络和基于卷积神经网络。例如,GRU4Rec 利用门控循环神经单元对用户行为序列进行编码。近年来,基于 Transformer 模型^[7]的序列推荐方法因其强大的序列建模能力而成为最先进的方法^[8-9]。CL4SRec^[28]将对比如学习应用于序列推荐的研究,为解决序列推荐中数据稀疏问题提供了新途径。在序列推荐研究领域快速发展的背景下,多行为序列推荐^[29]与跨域序列推荐^[30]这两种创新性范式,因能够更精准地捕捉用户复杂行为模式并有效突破单一领域数据局限,进而显著提升推荐系统性能。最近,随着状态空间模型^[10]的快速发展,基于选择性状态空间模型的序列推荐方法^[11-12]被引入以提高序列推荐的效率。现有大多数序列推荐方法主要关注于学习用户的短期偏好。

随着短视频平台的高度普及^[1],短视频用户序列的长度及累计观看数量的增长速度远超电商平台、新闻推荐等在线服务,越来越多的推荐系统领域研究者开始关注终身长序列推荐问题^[13, 31]。建模用户的长期交互序列(例如,用户交互序列长度 $\simeq 1k^{[15]}$)主要存在以下挑战:长序列用户行为数据的高效建模,以及用户行为序列中长期依赖的捕捉,同时还要关注到推荐场景中的数据稀疏问题。基于大语言模型的序列推荐方法^[32-35](例如,InstructRec 方法^[35])通常将商品描述作为输入,面临输入长度限制问题,虽然可以有效提升对用户短期偏好的学习,但对终身长序列的学习依然面临挑战。除此之外,基于大语言模型的推荐方法还面临大语言模型缺乏协同知识、推荐效率低等问题^[36-38]。随着最近 Mamba^[10](即一种具有选择机制的状态空间模型)和 xLSTM^[18]等新型模型架构的发布,为研究者提供了新的研究视角。因此,将上述新型模型架构应用于终身长序列推荐任务上成为了一个

值得探究的方向^[39-41]。

2.2 长短期记忆网络

长短期记忆网络^[20]是由 Hochreiter 等人于 1997 年提出的,是循环神经网络的一种改进架构,它在一定程度上缓解了循环神经网络难以捕捉长期依赖的问题。长短期记忆网络通过其内部状态控制信息的流动,这是通过一组包括输入、遗忘和输出门在内的门控单元实现的。这些门允许长短期记忆网络记住或忘记信息,从而更好地处理长期依赖问题。然而,长短期记忆网络由于其结构限制,在处理终身长序列时,难以解决长距离依赖问题。除此之外,由于其在训练期间的序列特性,很难并行化,导致效率低下。因此,长短期记忆网络在长距离依赖任务上的性能有限。

最近 Beck 等人提出的新型基于指数门控更新、标量与矩阵长短期记忆网络^[18-19](extended Long Short-Term Memory, xLSTM),对传统长短期记忆网络中的门控机制和记忆结构进行了改进。xLSTM 提出了标量记忆混合长短期记忆模块(Scalar LSTM, sLSTM)和矩阵长短期记忆模块(Matrix LSTM, mLSTM)两个模型变种,旨在解决传统长短期记忆网络的一些固有限制,并提高性能。标量长短期记忆单元引入了指数门控和标量更新机制以提高长序列建模的鲁棒性;而矩阵长短期记忆单元引入指数门控、矩阵内存、协方差更新规则和并行训练,将向量运算扩展到矩阵运算,提升了长期依赖信息的储存能力。这些模块通过层堆叠的方式及使用残差连接进行集成。xLSTM 在多项自然语言处理任务上的实验证明,其在长序列任务上展现出具有竞争力的性能,并且兼顾效率和可扩展性。此外, xLSTM 的适用性已在计算机视觉^[42]和数据挖掘^[43-44]等多个领域得到广泛验证与系统评估,进一步证实了其有效性。例如,在计算机视觉领域, Alkin 等人基于 xLSTM 模型结构提出了 Vision-LSTM^[42],其是一种高效的用于计算机视觉的交替双向扫描方法,通过在 ImageNet 数据集^[45]上的多项实验证明了其有效性。本文的目标是基于 xLSTM 模型设计适用于终身长序列推荐任务的高效方法。

3 形式化与研究动机

本节首先介绍任务定义,接着介绍 xLSTM 模型在推荐任务上的适用性分析,而后介绍本文的研究动机。

3.1 任务定义

序列推荐任务的目标是基于用户按时间顺序的物品交互序列,预测用户下一个可能交互的物品。现有大多数序列推荐方法主要关注于学习用户的短期偏好。终身长序列推荐任务^[14-15]是近年来新兴的一种序列推荐任务,旨在关注用户的长期交互序列(例如,用户交互序列长度 $\simeq 1k^{[15]}$),从而学习用户的长期偏好。形式上,给定一组用户 \mathcal{U} , 一组物品 \mathcal{V} , 以及用户与物品产生的交互,将每个用户 $u \in \mathcal{U}$ 交互过的物品按时间顺序排序,形成一个长度为 n 的交互序列 $S_u = [v_1, v_2, \dots, v_n]$, 其中 $v_i \in \mathcal{V}$ 表示序列中第 i 个交互的物品。遵循先前的研究工作^[13-14], 终身长序列推荐的目标是通过预测概率 $P(v_{n+1}|v_1, v_2, \dots, v_n)$ 来生成一个 Top-k 物品列表, 作为用户下一个可能会产生交互的物品。

3.2 xLSTM 在推荐任务上的适用性分析

3.2.1 任务特性差异

自然语言处理任务(例如,语言建模和机器翻译),通常存在较强的邻近依赖性和密集型上下文关联, xLSTM 的层堆叠方式使得深层堆叠能够有效捕捉不同粒度的语义特征。然而在序列推荐任务上,用户的交互行为序列呈现出以下特点:(1)行为间关联弱且稀疏:相邻交互物品之间不一定存在强关联,用户兴趣跳跃性大;(2)信息密度低:多数情况下,历史行为中真正对未来决策有贡献的行为较少。因此,在推荐任务上,过深的层堆叠反而容易引入噪声积累与过拟合风险,导致模型学习到无关或次要的信息。

3.2.2 性能与效率分析

为了验证 xLSTM 层堆叠方式在推荐任务上的适用性,本文进行了实证分析,如图 1 所示。实验结果表明:(1)由图 1(a)分析可得,在模型尺寸和推理 GPU 内存开销可比的情况下, sLSTM、mLSTM 和 xLSTM 应用于推荐任务上是有竞争力的方法。(2)由图 1(b)、(c)、(d)分析可得, xLSTM 堆叠方式性能难以大幅提升,但参数量和计算开销(Floating-point operations per second, FLOPs)却会大幅增加。对于推荐系统这样以实时应用为主,对效率要求很高的领域来说,在性能难以稳步提升,参数量和计算开销的却大幅度增长的情况是难以接受的。在推荐系统的实践中,过深的层堆叠会带来显著的计算资源开销和推理延迟问题,模型层数堆叠 2 层是较为常见的选择。因此,本文的目标是探索出一种 xLSTM 模型在推荐任务上的高效适用方式。

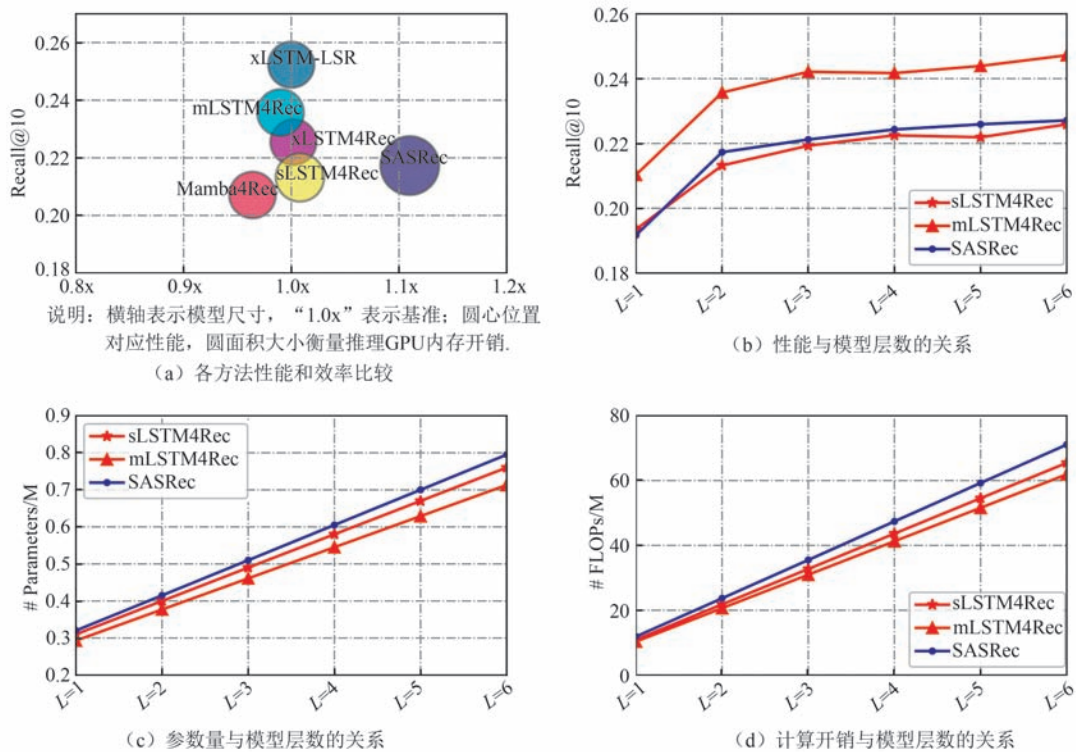


图1 xLSTM层堆叠方式在推荐任务上的性能和效率

3.3 研究动机

随着短视频等在线平台用户行为序列日益增长,如何在超长时间跨度内准确建模用户兴趣演变,成为推荐系统领域亟须解决的重要问题。传统序列推荐方法多聚焦于短期行为建模,将其直接应用于终身长序列推荐任务,例如基于Transformer的方法,亦在面向序列极长、依赖稀疏的推荐场景时暴露出效率低等问题。最近,xLSTM通过引入矩阵记忆与稳定化指数门控,显著提升了对长期依赖的建模能力,展现出良好的应用潜力。然而,xLSTM主要应用于自然语言处理任务,直接将其应用于推荐任务上难以取得理想的效果。基于此,本文提出基于矩阵与混合机制双流长短期记忆网络结构,旨在高效学习用户的长期稳定偏好与短期动态兴趣,推动终身长序列推荐任务在建模能力与系统可扩展性上的双重提升。

4 模型方法

本节首先介绍xLSTM-LSR方法的整体框架,接着介绍方法中各模块的具体设计及方法优势,而后对方法进行讨论。

4.1 方法整体框架

本文提出了基于矩阵与混合机制双流长短期记忆网络的终身长序列推荐方法xLSTM-LSR,分别采用矩阵长短期记忆网络学习用户的长期偏好,采用混合长短期记忆网络学习用户的短期偏好,而后采用门控网络进行长期偏好和短期偏好的融合,并设计了面向长短期偏好融合的对比学习策略,将xLSTM的能力整合到我们的终身长序列推荐方法框架中。xLSTM-LSR方法包括五个模块:(1)物品嵌入表示层:将给定物品列表中的各物品进行物品嵌入表示学习;(2)基于矩阵长短期记忆网络的用户长期偏好学习模块:通过矩阵长短期记忆网络学习各用户按时间顺序排列的行为数据,从而形成各用户的潜在长期偏好表示;(3)基于混合长短期记忆网络的用户短期偏好学习模块:通过混合长短期记忆网络学习各用户近期按时间顺序排列的某个长度范围的行为数据,从而形成各用户的潜在短期偏好表示;(4)基于门控网络的长期偏好和短期偏好融合模块:通过门控网络自适应学习不同数据集上长期偏好和短期偏好的占比,并对长短期偏好进行融合;(5)面向长短期偏好融合的对比学习策略:通过面向长短期融合的对比学习损失作为辅助监督信号,在已有门控网络融合模块的基础上,增强对表示空间

中融合向量结构的直接约束,进一步提升长短期偏好的融合效果。方法整体框架如图2所示。

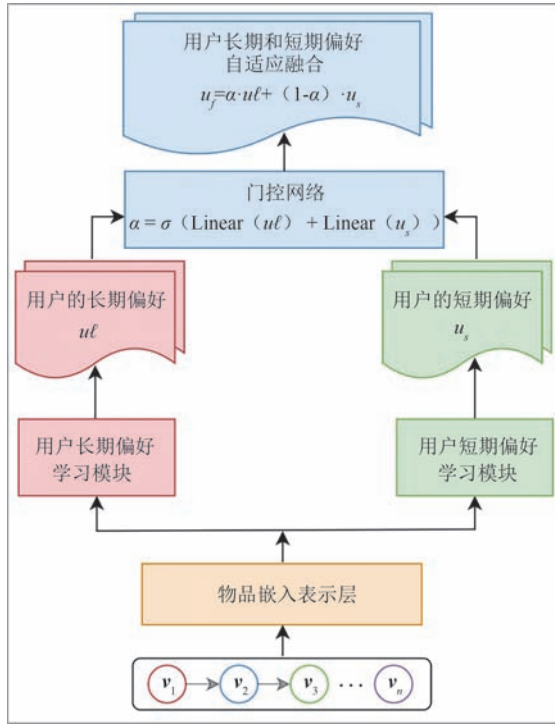


图2 xLSTM-LSR方法整体框架

4.2 物品嵌入表示层

在物品嵌入层,我们维护一个数据集中所有物品的嵌入表示矩阵 $\mathbf{M}_v \in \mathbb{R}^{M \times d}$, 将每个物品的高维独热编码表示投影到低维密集表示。给定一个包含 n 个物品的用户行为序列, 我们从 \mathbf{M}_v 中通过查找操作以形成物品序列嵌入表示 $\tilde{\mathbf{E}}_n \in \mathbb{R}^{n \times d}$ 。为了增强鲁棒性并防止过拟合, 我们在检索嵌入后引入了嵌入丢弃(Dropout)和层归一化。最终的序列表示 \mathbf{E}_n 可以通过层归一化和嵌入丢弃获得:

$$\mathbf{E}_n = \text{Dropout}(\text{LayerNorm}(\tilde{\mathbf{E}}_n)) \quad (1)$$

4.3 基于矩阵LSTM的用户长期偏好学习

为了克服传统长短期记忆网络在长期依赖问题上的局限性, xLSTM引入了矩阵记忆增强的mLSTM模块, 将传统长短期记忆网络的记忆单元从标量 $c \in \mathbb{R}$ 扩展到矩阵 $\mathbf{C} \in \mathbb{R}^{d \times d}$ 。因为用户的长期偏好趋向于稳定的偏好, 稳定偏好的发掘需要关注到整个终身长序列, 而矩阵记忆的记忆容量大且可以长距离传输, 适配终身长序列推荐任务中用户早期的行为偏好的长距离有效传递, 可以用于终身长序列推荐任务中用户长期偏好的学习, 所以本文采用矩阵长短期记忆网络构建用户长期偏好学习模块, 其结构如图3所示。

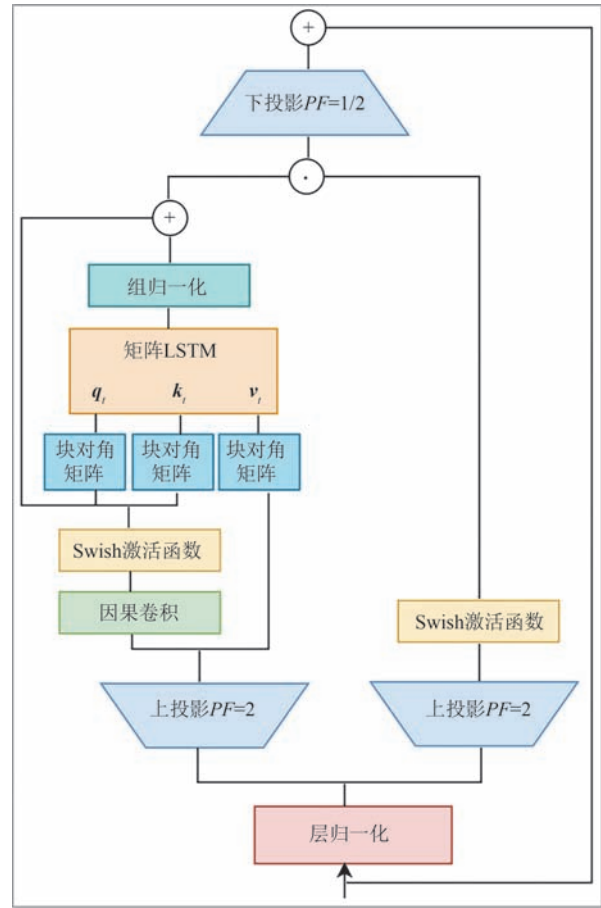


图3 用户长期偏好学习模块

在4.2节我们得到了用户行为序列中每个物品的嵌入表示, 我们将嵌入表示后的用户行为序列 $\mathbf{E}_n = (\mathbf{e}_{v_1}^u, \mathbf{e}_{v_2}^u, \dots, \mathbf{e}_{v_n}^u)$ 作为矩阵长短期记忆网络的输入。对于用户序列中的第 t 个物品, 对应存储一对向量(即键 $\mathbf{k}_t \in \mathbb{R}^d$ 和值 $\mathbf{v}_t \in \mathbb{R}^d$), 在序列的第 $t + \tau$ 个物品, 值 \mathbf{v}_t 通过查询向量 $\mathbf{q}_{t+\tau} \in \mathbb{R}^d$ 来检索, 其中检索是通过矩阵乘法实现的。在将输入映射到键和值之前进行层归一化, 使其具有零均值。上投影的投影因子(Projection Factor, PF)为2, 因果卷积的卷积核大小(Kernel Size)为4, 块对角矩阵的块大小(Block Size)为4, 下投影的投影因子为1/2。在协方差更新规则中, 遗忘门对应于衰减率, 输入门对应于学习率, 输出门则调整检索到的向量。存储键值对的协方差更新规则为 $\mathbf{C}_t = \mathbf{C}_{t-1} + \mathbf{v}_t \mathbf{k}_t^T$ 。除此之外, 由于矩阵长短期记忆网络中, 各记忆单元没有进行记忆混合, 采用并行化技术提升训练和推理效率^[18]。对于矩阵记忆, 归一化状态是键向量的加权和, 其中每个键向量由输入门和所有未来的遗忘门加权, 归一化状态记录门的强度。矩阵长短期记忆网络的前向传播中, 记忆单元状态和归一化状态为:

$$C_t = f_t C_{t-1} + i_t v_t k_t^T \quad (2)$$

$$n_t = f_t n_{t-1} + i_t k_t \quad (3)$$

其中, C_t 表示长短期记忆的记忆单元, 负责存储和传输长期依赖信息; n_t 是归一化状态; f_t 表示遗忘门; i_t 表示输入门。

矩阵长短期记忆网络前向传播中隐藏状态表示为:

$$h_t = o_t \odot \tilde{h}_t \quad (4)$$

$$\tilde{h}_t = \frac{C_t q_t}{\max(n_t^T q_t, 1)} \quad (5)$$

其中, o_t 表示输出门, q_t 表示查询向量。

矩阵长短期记忆网络前向传播中查询向量、键向量和值向量为:

$$q_t = W_q e_{v_t}^u + b_q \quad (6)$$

$$k_t = \frac{1}{\sqrt{d}} W_k e_{v_t}^u + b_k \quad (7)$$

$$v_t = W_v e_{v_t}^u + b_v \quad (8)$$

其中, W_q 、 W_k 、 W_v 、 b_q 、 b_k 和 b_v 表示可学习的参数。

矩阵长短期记忆网络前向传播中输入门、遗忘门和输出门表示为:

$$i_t = \exp(w_i^T e_{v_t}^u + b_i) \quad (9)$$

$$f_t = \exp(w_f^T e_{v_t}^u + b_f) \quad (10)$$

$$o_t = \sigma(W_o e_{v_t}^u + b_o) \quad (11)$$

其中, w_i^T 、 w_f^T 、 W_o 、 b_i 、 b_f 和 b_o 表示可学习的参数, σ 是 Sigmoid 函数。

指数激活函数可能导致出现过大值, 从而引起溢出。为了稳定矩阵长短期记忆网络的指数输入门与遗忘门, 对输入门和遗忘门采用了稳定化技术^[18], 公式如下:

$$i'_t = \exp(\log(i_t) - m_t) \quad (12)$$

$$f'_t = \exp(\log(f_t) + m_{t-1} - m_t) \quad (13)$$

$$m_t = \max(\log(f_t) + m_{t-1}, \log(i_t)) \quad (14)$$

其中, i'_t 和 f'_t 是经过稳定化技术后的输入门和遗忘门, m_t 是稳定技术过程状态。

经过上述步骤, 我们用矩阵长短期记忆网络学习了用户的长期偏好 u_t , 增强了记忆容量并大幅度缓解了长期依赖问题。相比于传统长短期记忆网络, 矩阵长短期记忆网络采用了并行化技术, 训练和推理效率也进一步得到提升。长期偏好通常体现为用户行为相对稳定的特征, 具有较高的时间一致性, 并能够反映用户在较长时间跨度内的核心偏好。这种偏好在动态特性上相对稳定, 通常不受短期上下

文或外部因素的显著干扰。通过对用户完整行为序列的建模与分析, 可以有效捕捉其相对稳定的长期偏好特征。

4.4 基于混合 LSTM 的用户短期偏好学习

为了克服传统长短期记忆网络在修正记忆决策问题上的局限性, xLSTM 引入了拥有稳定化指数门的 sLSTM 模块, 将输入门和遗忘门变更为指数激活函数, 将输入门与未来遗忘门的乘积求和作为归一化状态, 通过指数门实现记忆的混合。通过 xLSTM 模型在自然语言处理任务的实验表明, sLSTM 在获取短期依赖上相比传统长短期记忆网络有较为显著的提升。在终身长序列推荐任务中, 不仅要关注用户的长期偏好, 还要关注用户的短期偏好, 短期偏好往往能够反映用户当前的兴趣和需求。因为用户的短期行为偏好更注重近期行为之间的联系, 而混合记忆适合发现用户行为序列中各行之间的联系, 所以本文采用混合长短期记忆网络构建用户短期偏好学习模块, 其结构如图 4 所示。

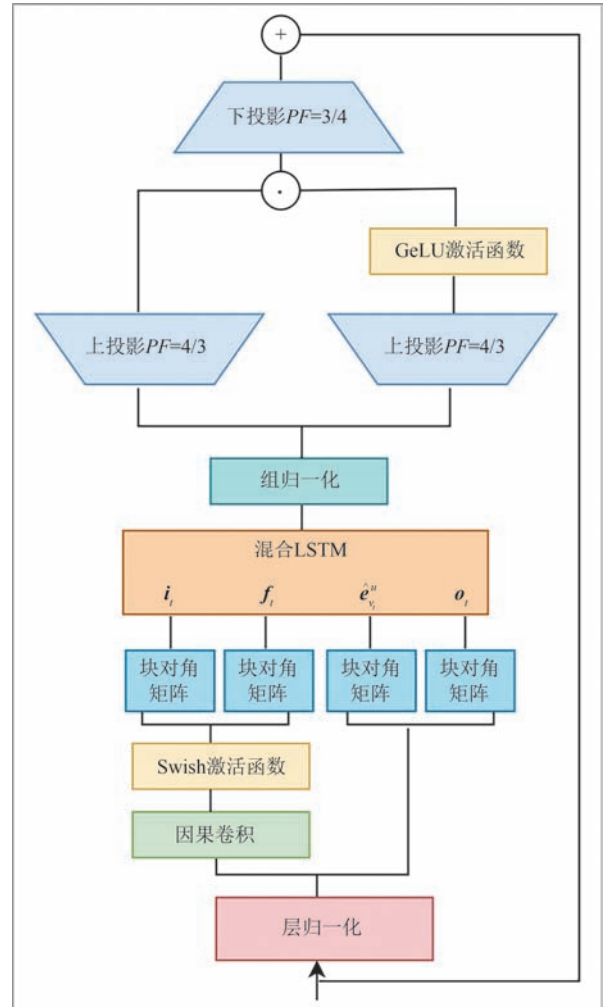


图4 用户短期偏好学习模块

在4.2节我们得到了用户行为序列中每个物品的嵌入表示,我们将嵌入表示后的用户行为序列 $\mathbf{E}_n = (\mathbf{e}_{v_1}^u, \mathbf{e}_{v_2}^u, \dots, \mathbf{e}_{v_n}^u)$, 对于用户的短期偏好,我们取用户最近的 m 次行为,即 $\mathbf{E}_m = (\mathbf{e}_{v_{n-m+1}}^u, \mathbf{e}_{v_{n-m+2}}^u, \dots, \mathbf{e}_{v_n}^u)$, 作为混合长短期记忆网络的输入。因果卷积的卷积核大小(Kernel Size, KS)为4,块对角矩阵的块大小(Block Size)为4,上投影的投影因子为4/3,下投影的投影因子为3/4。混合长短期记忆网络的前向传播中,记忆单元状态、归一化状态和隐藏状态为:

$$c_t = \mathbf{f}_t \cdot c_{t-1} + \mathbf{i}_t \cdot \hat{\mathbf{e}}_{v_t}^u \quad (15)$$

$$n_t = \mathbf{f}_t \cdot n_{t-1} + \mathbf{i}_t \quad (16)$$

$$h_t = \mathbf{o}_t \cdot \frac{c_t}{n_t} \quad (17)$$

其中, $\hat{\mathbf{e}}_{v_t}^u$ 表示记忆单元的输入。

混合长短期记忆网络前向传播中记忆单元的输入表示为:

$$\hat{\mathbf{e}}_{v_t}^u = \tanh(\mathbf{w}_c^T \cdot \mathbf{e}_{v_t}^u + r_c \cdot h_{t-1} + b_c) \quad (18)$$

其中, \mathbf{w}_c^T , r_c 和 b_c 表示可学习的参数。

混合长短期记忆网络前向传播中输入门、遗忘门和输出门表示为:

$$\mathbf{i}_t = \exp(\mathbf{w}_i^T \cdot \mathbf{e}_{v_t}^u + r_i \cdot h_{t-1} + b_i) \quad (19)$$

$$\mathbf{f}_t = \exp(\mathbf{w}_f^T \cdot \mathbf{e}_{v_t}^u + r_f \cdot h_{t-1} + b_f) \quad (20)$$

$$\mathbf{o}_t = \sigma(\mathbf{w}_o^T \cdot \mathbf{e}_{v_t}^u + r_o \cdot h_{t-1} + b_o) \quad (21)$$

其中, \mathbf{w}_i^T , \mathbf{w}_f^T , \mathbf{w}_o^T , r_i , r_f , r_o , b_i , b_f 和 b_o 表示可学习的参数。

经过上述步骤,我们用混合长短期记忆网络学习了用户的短期偏好 u_s , 增强了修正记忆决策的能力。相比于传统长短期记忆网络,混合长短期记忆网络增强了学习用户行为短期偏好的能力。短期偏好通常受到即时上下文或外部因素的显著影响,表现出较高的动态性。通过分析用户最近的 m 次行为数据,可以有效捕捉其短期偏好特征,并在一定程度上反映其即时需求。

4.5 基于门控网络的长短期偏好自适应融合

在4.3节和4.4节,经过矩阵长短期记忆网络获得了用户的长期偏好表示 u_ℓ , 经过混合长短期记忆网络获得了用户的短期偏好表示 u_s 。在本节,我们通过门控网络自适应调节用户的长期偏好和短期偏好在用户整体偏好中所占的比例。

门控网络计算用户的长期偏好表示 u_ℓ 和用户的短期偏好表示 u_s 在用户的整体偏好中的占比,通过如下公式计算长期偏好的权重:

$$\alpha = \sigma(\mathbf{W}_\ell u_\ell + \mathbf{W}_s u_s + b_\ell) \quad (22)$$

其中, \mathbf{W}_ℓ , \mathbf{W}_s 和 b_ℓ 是可学习的参数。

用户长期偏好和短期偏好融合后的用户整体偏好表示为:

$$u_f = \alpha \cdot u_\ell + (1 - \alpha) \cdot u_s \quad (23)$$

经过上述步骤,我们采用门控网络获得了用户长期偏好和短期偏好自适应融合后的用户整体偏好 u_f 。长期偏好通常反映了用户行为或系统状态的稳定特征,具有较高的时间一致性,而短期偏好则更多地受到即时上下文或外部因素的影响,表现出较高的动态性。通过门控网络,能够根据数据集的分布特点自适应调节长期偏好和短期偏好所占比例,根据用户的历史行为序列和即时需求,动态融合长短期偏好,从而更好地发掘长期偏好对用户的影响,以及适应变化频繁的用户短期偏好,提升在不同数据分布的推荐场景中预测的准确性。

4.6 面向长短期偏好融合的对比学习策略

为进一步提升长期偏好与短期偏好的融合效果,增强融合表示的判别能力与个性化特征表达能力,本文提出了面向长短期融合的对比学习(Contrastive Learning, CL)损失作为辅助监督信号。在已有门控网络融合策略的基础上,增强对表示空间中融合向量结构的直接约束,该损失鼓励融合表示在表示空间中更加接近自身的长期与短期偏好向量,同时远离其他用户的长期与短期表示,从而提升融合偏好表示的个性化表达能力与语义一致性。面向长短期融合的对比学习损失函数如下:

$$\mathcal{L}_{CL} = -\log \frac{e^{\text{sim}(u_f, u_\ell)/\tau} + e^{\text{sim}(u_f, u_s)/\tau}}{\sum_{j=1}^B (e^{\text{sim}(u_f, u_\ell^j)/\tau} + e^{\text{sim}(u_f, u_s^j)/\tau})} \quad (24)$$

其中, $\text{sim}(a, b) = \frac{a^T b}{\|a\| \|b\|}$ 为余弦相似度, $\tau > 0$

为温度系数, B 为批量样本数, u_ℓ^j 和 u_s^j 分别为批内第 j 个用户的长期与短期偏好。在该损失下,融合表示 u_f 被鼓励与自身的长期、短期偏好保持更高的相似度,同时远离其他用户的子偏好表示,增强了表示空间中的用户个性区分度。

通过面向长短期融合的对比学习策略,一方面增强了信息对齐,使融合表示更加贴近其组成成分(即用户的长期偏好和短期偏好);另一方面提升了模型的泛化能力,抑制融合表示的偏置行为,减少退化为单一偏好来源,构建类簇结构良好的用户偏好表示空间。

4.7 模型训练

4.7.1 预测层

在推理阶段,对于一个用户的表示 u_f ,我们用下一个可能交互的任意物品 v_i 的概率,来衡量用户的潜在偏好:

$$P(v_i|u_f)=\text{Softmax}(u_f\cdot e_{v_i}) \tag{25}$$

其中, e_{v_i} 是物品 v_i 对应的物品表示。

4.7.2 学习目标

在用户行为序列中前 n 个物品编码后,基于门控网络得到的长短期偏好融合的用户表示 u_f 来预测用户可能产生交互的下一个物品。我们采用交叉熵损失来训练模型:

$$\mathcal{L}_{\text{CE}}=-\log\frac{e^{<u_f,e_g>}}{\sum_{i=1}^{|V|}e^{<u_f,e_{v_i}>}} \tag{26}$$

其中, g 是用户下一个真实交互的正例物品, $|V|$ 是数据集中所有物品的数量。

最终模型的总体学习目标由主任务预测损失与对比学习损失组成:

$$\mathcal{L}=\mathcal{L}_{\text{CE}}+\lambda\cdot\mathcal{L}_{\text{CL}} \tag{27}$$

其中, λ 为控制对比损失权重的超参数。

4.8 关于方法的讨论

本文提出的 xLSTM-LSR 方法与基于 Transformer 模型的推荐方法、基于状态空间模型的推荐方法以及基于循环神经网络变种的推荐方法的效率比较如表 1 所示。相比基于传统循环神经网络的序列推荐方法^[6, 46], xLSTM-LSR 提升了训练时间效率。相比基于 Transformer 模型的方法^[8, 9, 47], xLSTM-LSR 提升了推理时间效率。xLSTM-LSR 与基于状态空间模型的方法都具有较高的效率。2.1 节对基于大语言模型的推荐方法进行了讨论,由于基于大语言模型的推荐方法在解决终身长序列推荐任务时存在输入长度限制、缺乏协同知识、效率低等问题,因此本节没有比较基于大语言模型的推荐方法。

在模型结构方面,与基于循环神经网络的 GRU4Rec 等相比,本文提出的 xLSTM-LSR 方法采用矩阵记忆扩大了记忆容量并提升了长距离传输能力;与基于 Transformer 的 SASRec、BERT4Rec 等相比,SASRec、BERT4Rec 因为自注意力机制的平方计算时间复杂度限制较难拓展到终身长序列推荐场景,而 xLSTM-LSR 基于新型循环神经网络结构并采用稳定化技术,在建模用户长期兴趣偏好时,

表 1 各方法效率比较

类别	方法	训练时间 效率	推理时间 效率	并行 计算
循环神经网络	GRU4Rec	×	√	×
	MIMN	×	√	×
Transformer	SASRec	√	×	√
	BERT4Rec	√	×	√
状态空间模型	Mamba4Rec	√	√	√
本文提出 与实现的方法	xLSTM-LSR	√	√	√
	RNN4Rec	×	√	×
	LSTM4Rec	×	√	×
	BiLSTM4Rec	×	√	×
	sLSTM4Rec	×	√	×
	mLSTM4Rec	√	√	√
	xLSTM4Rec	√	√	×

采用完整的长度为 n 的用户序列,在建模用户短期兴趣偏好时,采用用户最近 m 次行为(m 取 10, 20, 30),这部分计算开销远低于长期兴趣建模,因而模型整体效率主要取决于长期兴趣建模部分,整体接近于线性推理复杂度;与基于状态空间模型的 Mamba4Rec 等相比, xLSTM-LSR 采用了矩阵记忆,具有更大的记忆传输容量,可以在一定程度上提升推荐性能;与最近的代表性序列推荐模型 LSAN^[47]等相比,LSAN 采用低秩自注意力机制解决自注意力机制的效率问题,但其推荐性能受限,而 xLSTM-LSR 扩大了记忆容量并提升了长距离传输能力,具有更好的推荐性能。

5 实验和分析

5.1 数据集

本文在四个公开数据集上进行实验,分别是序列推荐数据集 MovieLens 的 100K 子集、1M 子集和 Amazon Review^[21]的 Pantry 子集和 Books 子集,及终身长序列推荐数据集 LFM-1b^[22]和 KuaiRand^[23],各数据集的统计信息如表 2 所示。对于每个数据集,按照用户维度来提取交互记录,而后为每个用户

表 2 实验数据统计信息

数据集	#用户	#物品	#交互	平均长度	稀疏度
ML-100K	942	1682	99188	105.30	93.74%
ML-1M	6041	3707	1000209	165.60	95.53%
Pantry	13101	4898	126962	9.69	99.82%
Books	150402	1005367	4381266	29.13	99.99%
LFM-1b	120320	31634435	1088161692	9042.86	99.97%
KuaiRand	27285	32038725	322278385	11810.50	99.96%

生成按时间顺序排列的物品序列。

(1) MovieLens 数据集

MovieLens 数据集是一个由 GroupLens Research 实验室整理的公开数据集, 广泛用于推荐算法的研究和评估。其数据主要由用户 ID、电影 ID、评分和时间戳构成。

(2) Amazon Review 数据集

Amazon Review 数据集是一个多维度、大规模的用户评价资源, 广泛应用于推荐系统领域研究。它详细记录了用户在亚马逊网站上对各类商品的评分、文本评价和有建议性的评分, 涵盖了从书籍到电子产品等多个商品类别。Pantry 和 Books 是 Amazon Review 数据集的类别子集。为了降低数据集的稀疏度、增加序列长度来验证各方法对终身长序列推荐任务的效果, 我们对 Pantry 和 Books 数据集依据序列长度阈值进行了预处理。

(3) LFM-1b 数据集

LFM-1b 数据集是一个超过 10 亿次音乐收听事件的大规模公开数据集, 由超过 12 万名 Last. fm 用户的收听历史组成。LFM-1b 数据集平均序列长度达到约 9043, 为终身长序列推荐任务提供了重要参考。考虑到基于 Transformer 模型的序列推荐方法 GPU 内存占用大等资源限制的问题, 为了实验的公平性, 本文将各方法在 LFM-1b 上的用户序列长度取为 1k。

(4) KuaiRand 数据集

KuaiRand 数据集是一个由中国科学技术大学和快手公司等发布的无偏短视频序列推荐公开数据集。KuaiRand 数据集支持包括去偏、交互式推荐、长序列行为建模和多任务学习在内的多种推荐任务研究。本文将各方法在 KuaiRand 上的用户序列长度取为 1k。

5.2 对比模型和本文提出的方法

本文选用四类对比方法: (1) 基于循环神经网络的方法 (2) 基于 Transformer 模型的方法 (3) 基于状态空间模型的方法 (4) 本文提出与实现的方法。

(1) 基于 Transformer 模型的推荐方法

SASRec^[8]: 是一种通过自注意力机制有效捕捉用户历史行为中依赖关系的序列推荐模型。

BERT4Rec^[9]: 是一种采用双向自注意力机制, 并使用填空任务来捕捉用户行为序列中的丰富上下文信息, 从而进行序列推荐。

(2) 基于状态空间模型的推荐方法

Mamba4Rec^[11]: 是一种基于选择性状态空间模

型 (Selective State Space Models, SSMs) 的高效序列推荐方法, 旨在解决现有基于 Transformer 的模型在长序列推理中的效率问题。

(3) 基于循环神经网络的推荐方法

GRU4Rec^[6]: 是一种基于门控循环单元 (Gated Recurrent Unit, GRU) 的序列推荐模型, 通过学习用户历史行为序列中的状态转移模式, 利用 GRU 的门控机制来记忆和遗忘信息, 从而实现个性化推荐。该模型能够有效处理用户行为序列数据, 并且能够处理稀疏数据, 适用于多种推荐场景。尽管 GRU4Rec 在处理长序列时可能面临记忆遗忘和计算效率的挑战, 但其强大的序列建模能力使其成为推荐领域一个重要基准方法。

MIMN^{*[15]}: MIMN 模型借鉴自然语言处理领域的记忆神经网络思想, 用于解决点击率预估问题中的长序列建模问题。由于 MIMN 模型的评测方式与本文的不同, 因此, 我们对 MIMN 模型与序列推荐的评测方式进行了适配, 称为 MIMN^{*}。

(4) 本文提出与实现的方法

本文提出了终身长序列推荐方法 xLSTM-LSR, 除此之外, 还实现了基于循环神经网络变种的序列推荐方法 RNN4Rec、LSTM4Rec、BiLSTM4Rec、sLSTM4Rec、mLSTM4Rec 和 xLSTM4Rec。

xLSTM-LSR: 是本文提出的终身长序列推荐方法, 即采用门控网络融合矩阵与混合双流长短期记忆网络。

RNN4Rec: 是本文实现的一种序列推荐方法, 采用传统循环神经网络来捕捉用户行为序列中的时序依赖性, 预测用户可能感兴趣的物品。

LSTM4Rec: 是本文实现的一种序列推荐方法, 采用传统长短期记忆网络来捕捉用户行为中的依赖关系, 通过输入门、遗忘门和输出门控制信息流动, 一定程度上缓解了循环神经网络长序列训练中梯度消失或爆炸问题。

BiLSTM4Rec: 是本文实现的一种序列推荐方法, 采用双向长短期记忆网络来处理序列推荐数据, 双向不仅会从前往后建模用户行为序列, 也会从后往前建模用户行为序列。

sLSTM4Rec: 是本文实现的一种序列推荐方法, 采用 xLSTM 中的 sLSTM 层来建模用户行为序列数据。

mLSTM4Rec: 是本文实现的一种基于长短期记忆网络的变种序列推荐方法, 采用 xLSTM 中的 mLSTM 层来建模用户行为序列数据。

xLSTM4Rec:是本文实现的一种序列推荐方法,采用xLSTM中的sLSTM层与mLSTM层堆叠方式建模用户行为序列数据。

5.3 评价指标

遵循先前的工作^[8, 48],我们采用留一法(Leave-one-out)交叉验证,并利用在Top-k物品上的召回率(Recall),归一化折扣累积增益(Normalized Discounted Cumulative Gain, NDCG)和平均倒数排名(Mean Reciprocal Rank, MRR)来评估性能($k \in \{5, 10\}$)。按照Krichene等人的建议^[49],在测试阶段我们对数据集中所有物品进行排名,而不是进行抽样评估。

5.4 实现细节

本文所有实验代码均使用PyTorch并基于开源推荐框架RecBole^[50]实现,在NVIDIA A800 80G上进行实验。本文的代码实现参考了xLSTM的官方

版本代码。本文各方法在各数据集上的超参数选取如下:物品嵌入表示层维度 $\in [32, 64, 128, 256]$,实验批次大小 $\in [16, 32, 64, 128]$,学习率取值 $\in [0.0005, 0.001, 0.005, 0.01]$,丢弃率取值 $\in [0.0, 0.1, 0.2]$,L2正则化取值 $\in [1, 0.1, 0.01, 0.001, 0.0001, 0]$,实验中我们使用Adam优化器进行参数更新,最大训练轮数为300。

5.5 实验结果

序列推荐数据集实验结果如表3所示,终身长序列推荐数据集实验结果如表4所示。表3和表4均为三部分,分别展示基线方法(包括基于循环神经网络的方法、基于Transformer模型的方法和基于状态空间模型的方法)、本文实现的变种方法及本文提出的xLSTM-LSR方法结果。不同方法在同一数据集下均保持一致的用户和相同的最大序列长度。通过实验,可以得到以下结论:

表3 xLSTM-LSR及对比模型实验结果(序列推荐数据集)

数据集	评价指标	GRU4Rec	SASRec	BERT4Rec	Mamba4Rec	MIMN [*]	sLSTM	mLSTM	xLSTM	xLSTM-LSR	提升
ML-100K	Recall@5	0.0520	0.0660	0.0668	0.0647	0.0605	0.0639	0.0667	0.0650	0.0753*	+12.72%
	Recall@10	0.1192	0.1395	0.1291	0.1245	0.1279	0.1288	0.1341	0.1315	0.1489*	+6.74%
	NDCG@5	0.0325	0.0429	0.0405	0.0399	0.0375	0.0396	0.0397	0.0409	0.0483*	+12.59%
	NDCG@10	0.0607	0.0624	0.0635	0.0592	0.0613	0.0579	0.0643	0.0585	0.0710*	+10.42%
	MRR@5	0.0325	0.0330	0.0357	0.0359	0.0343	0.0326	0.0352	0.0349	0.0389*	+8.96%
	MRR@10	0.0415	0.0434	0.0453	0.0382	0.0437	0.0379	0.0443	0.0385	0.0475*	+4.86%
ML-1M	Recall@5	0.1392	0.1376	0.1429	0.1305	0.1410	0.1274	0.1356	0.1295	0.1497*	+4.76%
	Recall@10	0.2095	0.2173	0.2135	0.2071	0.2128	0.2132	0.2357	0.2255	0.2523*	+7.04%
	NDCG@5	0.0809	0.0829	0.0858	0.0862	0.0807	0.0821	0.0864	0.0829	0.0925*	+7.31%
	NDCG@10	0.1061	0.1109	0.1081	0.1025	0.1070	0.1053	0.1195	0.1069	0.1340*	+12.13%
	MRR@5	0.0646	0.0655	0.0680	0.0647	0.0639	0.0629	0.0674	0.0665	0.0712*	+4.71%
	MRR@10	0.0748	0.0769	0.0811	0.0829	0.0735	0.0712	0.0792	0.0741	0.0861*	+3.86%
Pantry	Recall@5	0.0840	0.0855	0.0814	0.0851	0.0833	0.0846	0.0858	0.0834	0.0927*	+8.04%
	Recall@10	0.0972	0.1017	0.1067	0.1041	0.0969	0.1046	0.1069	0.1050	0.1149*	+7.48%
	NDCG@5	0.0615	0.0660	0.0695	0.0671	0.0634	0.0604	0.0659	0.0639	0.0731*	+5.18%
	NDCG@10	0.0670	0.0698	0.0710	0.0672	0.0682	0.0695	0.0746	0.0739	0.0797*	+6.84%
	MRR@5	0.0525	0.0610	0.0605	0.0594	0.0539	0.0589	0.0617	0.0604	0.0650*	+5.35%
	MRR@10	0.0570	0.0627	0.0635	0.0602	0.0583	0.0611	<u>0.0643</u>	0.0630	0.0679*	+5.60%
Books	Recall@5	0.0695	0.0680	0.0714	0.0658	0.0702	0.0718	0.0707	0.0684	0.0763*	+6.27%
	Recall@10	0.0794	0.0885	0.0893	0.0862	0.0817	0.0873	0.0895	0.0879	0.0930*	+3.91%
	NDCG@5	0.0415	0.0430	0.0395	0.0411	0.0423	0.0404	0.0449	0.0435	0.0462*	+2.90%
	NDCG@10	0.0448	0.0470	0.0461	0.0432	0.0451	0.0455	0.0468	0.0451	0.0497*	+5.74%
	MRR@5	0.0325	0.0360	0.0355	0.0379	0.0347	0.0366	0.0357	0.0380	0.0394*	+3.68%
	MRR@10	0.0405	0.0384	0.0375	0.0403	0.0395	0.0415	0.0412	0.0407	0.0437*	+5.30%

注:黑体表示在本行效果最好;*表示xLSTM-LSR超越次优方法通过了显著性检验(t 检验, $p < 0.05$)。

(1)对比基于循环神经网络的推荐方法
相比基于传统循环神经网络的序列推荐方法(例

如GRU4Rec或MIMN^{*}),本文提出的xLSTM-LSR方法在序列推荐数据集与终身长序列推荐数据集上

表4 xLSTM-LSR 及对比模型实验结果(终身长序列推荐数据集)											
数据集	评价指标	GRU4Rec	SASRec	BERT4Rec	Mamba4Rec	MIMN*	sLSTM	mLSTM	xLSTM	xLSTM-LSR	提升
LFM-1b	Recall@5	0.3020	0.3260	0.3249	0.3353	0.3195	0.3357	0.3439	0.3350	0.3569*	+3.78%
	Recall@10	0.3392	0.3595	0.3401	0.3795	0.3524	0.3688	0.3741	0.3635	0.3986*	+5.03%
	NDCG@5	0.1852	0.2329	0.2305	0.2429	0.2094	0.2316	0.2385	0.2400	0.2425	—
	NDCG@10	0.1907	0.2484	0.2475	0.2582	0.2182	0.2573	0.2597	0.2565	0.2713*	+4.47%
	MRR@5	0.1725	0.1810	0.1805	0.1893	0.1805	0.1904	0.1997	0.1925	0.2090*	+4.66%
	MRR@10	0.1907	0.1984	0.2075	0.2182	0.1987	0.2079	0.2118	0.2098	0.2311*	+5.91%
KuaiRand	Recall@5	0.2040	0.2305	0.2314	0.2523	0.2285	0.2479	0.2569	0.2515	0.2705*	+5.29%
	Recall@10	0.2312	0.2797	0.2805	0.2993	0.2660	0.2814	0.2895	0.2919	0.3079*	+2.87%
	NDCG@5	0.1741	0.2013	0.2078	0.2169	0.1983	0.2174	0.2195	0.2201	0.2283*	+3.73%
	NDCG@10	0.2170	0.2528	0.2520	0.2392	0.2408	0.2534	0.2672	0.2597	0.2765*	+3.48%
	MRR@5	0.1309	0.1695	0.1723	0.1814	0.1683	0.1809	0.1827	0.1865	0.1927*	+3.32%
	MRR@10	0.1812	0.2101	0.2135	0.2290	0.2069	0.2265	0.2334	0.2310	0.2473*	+5.96%

注:黑体表示在本行效果最好;*表示 xLSTM-LSR 超越次优方法通过了显著性检验(t 检验, $p < 0.05$)。

均具有显著优势,在 ML-1M、Books 和 KuaiRand 等数据集上取得了显著的提升。一方面是因为基于矩阵长短期记忆网络的用户长期偏好学习模块增强了记忆容量以及记忆的传递,大幅度缓解了用户行为序列中的长期依赖问题,有效地解决了信息遗忘和梯度消失等问题,从而能够更准确地学习用户行为序列中的长期偏好;另一方面是因为基于混合长短期记忆网络的用户短期偏好学习模块增强了用户行为序列中各物品记忆的混合与传递,提升了用户短期偏好学习的能力。因此,与基于传统循环神经网络的序列推荐方法相比,xLSTM-LSR 方法在序列推荐与终身序列推荐任务上可以取得显著的提升。

(2)对比基于 Transformer 模型的推荐方法

与基于 Transformer 模型的序列推荐方法(例如 SASRec、BERT4Rec)相比,不同数据集下的表现按照数据集划分具有一定规律:大部分情况下,本文提出的 xLSTM-LSR 方法优于基于 Transformer 模型的方法,mLSTM4Rec 方法在终身长序列推荐数据集上与基于 Transformer 模型的方法性能相当,sLSTM4Rec 方法在序列推荐数据集上与基于 Transformer 模型的方法性能接近。在个别指标上,SASRec 或 BERT4Rec 表现优异,一方面是因为推荐系统是一个高度实践的研究领域,模型性能往往受到多种因素的影响,工业推荐数据集中也可能存在一定噪声,有时用户的行为存在一定的偶然性;另一方面,不同类型的推荐模型在处理特定类型数据或任务时可能会表现出不同的优势和局限性。尽管如此,在大多数情况下,xLSTM-LSR 模型通过其双流方式建模长短期偏好、门控网络融合和对比学

习策略,在推荐性能上显著超过了其他基线方法。除此之外,相比于 BERT4Rec,xLSTM-LSR 模型在终身长序列场景拥有更高的效率。

在终身长序列推荐任务上,xLSTM-LSR 在 LFM-1b 和 KuaiRand 数据集上的 NDCG 指标显著优于 SASRec 和 BERT4Rec。因此,xLSTM-LSR 在终身长序列推荐任务上相比基于 Transformer 的方法具有更强的排序能力。mLSTM4Rec 在大部分情况下 NDCG 指标也优于 SASRec 和 BERT4Rec,说明了矩阵长短期记忆网络在建模终身长序列上的有效性。除此之外,基于 Transformer 模型的序列推荐方法在模型训练和推理过程中需要的 GPU 内存显著高于 xLSTM-LSR 和 mLSTM4Rec,关于模型效率的分析在 5.6.4 节,总体而言,xLSTM-LSR 在性能上优于基于 Transformer 的方法,尤其是在终身长序列推荐任务上的 NDCG 排序指标显著优于基于 Transformer 的方法,在同时考虑性能和效率时相比基于 Transformer 的方法具备显著优势。

在序列推荐任务上,xLSTM-LSR 在 ML-100K、ML-1M 和 Pantry 数据集上的 NDCG 指标优于 SASRec 和 BERT4Rec,Recall 指标大部分情况下优于 SASRec 和 BERT4Rec。这表明 xLSTM-LSR 在建模用户短期偏好方面同样具备优异的性能。sLSTM4Rec 在 ML-100K 和 ML-1M 数据集上的表现与 SASRec 较为接近,在 Pantry 与 Books 数据集上的表现与 BERT4Rec 较为接近,说明了混合长短期记忆网络在建模用户短期偏好方面的有效性。

(3)对比基于状态空间模型的推荐方法

基于状态空间模型的序列推荐方法(例如

Mamba4Rec)能够有效缓解长期依赖问题,随着序列长度的增加,有着优异的可扩展性。与基于状态空间模型的序列推荐方法相比,本文提出的xLSTM-LSR在终身长序列推荐数据集上的多个指标上表现出了更好的性能。在序列推荐数据集上,xLSTM-LSR相比基于状态空间模型的方法具有显著的优势。

从mLSTM4Rec和Mamba4Rec在终身长序列推荐数据集上的实验结果对比可以得出,在学习用户长期偏好方面,基于矩阵长短期记忆网络的模型与基于Mamba的模型有着相近的性能。从sLSTM4Rec和Mamba4Rec在序列推荐数据集上的实验结果对比可以得出,在学习用户短期偏好方面,基于混合长短期记忆网络的模型相比基于Mamba的模型有显著优势。因此,基于状态空间模型的序列推荐方法(例如Mamba4Rec)在学习用户长期偏好上有着优异的性能,但在建模用户短期偏好方面的能力还有待提升。

(4)对比基于循环神经网络变种的推荐方法

本文提出的以双流方式将矩阵与混合长短期记忆网络应用于终身长序列任务的方法xLSTM-LSR,相比于层堆叠方式应用矩阵与混合长短期记忆网络的方法xLSTM4Rec在终身长序列推荐和序列推荐数据集上均有显著提升。相比基于传统循环神经网络的序列推荐方法(如RNN4Rec、LSTM4Rec和BiLSTM4Rec),xLSTM-LSR有显著提升,详细分析在5.6.5节。相比基于新型循环神经网络xLSTM的序列推荐方法(例如sLSTM4Rec、mLSTM4Rec和xLSTM4Rec),xLSTM-LSR均有提升,大多数情况下提升显著。sLSTM4Rec在序列推荐数据集上的表现要优于在终身长序列推荐数据集上的表现,由此说明了混合长短期记忆网络在建模用户短期偏好方面的有效性。因此xLSTM-LSR设计了双流方式矩阵与混合长短期记忆网络,相比层堆叠方式,在推荐系统领域更有效。

总体而言,xLSTM-LSR以高效率同时建模了用户长期偏好和短期偏好,而后自适应进行长短期偏好的融合,并采用面向长短期偏好融合的对比学习策略进一步提升融合表示的判别能力与个性化特征表达能力。在建模终身长序列任务上,相比基于传统循环神经网络的方法具有显著的性能优势,相比基于Transformer的方法具有显著的效率优势,相比基于Mamba的方法具有更优的推荐性能;在序列

推荐数据集上,xLSTM-LSR相比基线方法同样具备更优的性能。

5.6 实验分析

5.6.1 消融实验

本节分别讨论xLSTM-LSR中各模块对方法效果的影响,分别使用ML-1M和LFM-1b数据集进行实验。消融实验结果如表5所示。其中“w/o GN”代表将方法中自适应融合用户长期和短期偏好的门控网络替换为等权重融合;“w/o MTX”代表将方法中的矩阵长短期记忆网络替换为传统长短期记忆网络;“w/o MIX”代表将方法中的混合长短期记忆网络替换为传统长短期记忆网络;“w/o MTXE”代表将矩阵长短期记忆网络中稳定化技术的指数门替换为Sigmoid门;“w/o MIXE”代表将混合长短期记忆网络中稳定化技术的指数门替换为Sigmoid门;“w/o CL”代表去掉面向长短期偏好融合的对比如学习策略;“w/o LN”代表去掉层归一化和丢弃操作。

表5 xLSTM-LSR方法消融实验结果

方法	ML-1M		LFM-1b	
	Recall@10	NDCG@10	Recall@10	NDCG@10
xLSTM-LSR	0.2523	0.1340	0.3986	0.2713
w/o GN	0.2387	0.1201	0.3634	0.2475
w/o MTX	0.2230	0.1179	0.3565	0.2397
w/o MIX	0.2341	0.1213	0.3805	0.2595
w/o MTXE	0.2343	0.1205	0.3729	0.2564
w/o MIXE	0.2378	0.1225	0.3809	0.2614
w/o CL	0.2473	0.1281	0.3945	0.2670
w/o LN	0.2328	0.1197	0.3630	0.2481

“w/o GN”的实验结果表明,采用门控网络进行用户长期和短期偏好融合可以较好地适应不同数据集的数据分布。相比之下,采用简单的等权重融合策略难以充分捕捉在不同数据分布特征下的长期偏好和短期偏好的权重变化,导致模型的表达能力受限,从而影响推荐性能。“w/o MTX”表明了在学习用户长期偏好上采用矩阵长短期记忆网络的必要性。“w/o MIX”表明了在学习用户短期偏好上采用混合长短期记忆网络的必要性。“w/o MTXE”和“w/o MIXE”表明,采用稳定化技术的指数门的模型性能显著优于替换为Sigmoid门,门控机制控制信息的流动,稳定化技术的指数门一定程度上缓解了梯度消失或梯度爆炸问题。“w/o CL”表明,面向长短期偏好融合的对比如学习策略提升了长短期偏好

融合的效果,增强了融合表示的判别能力与个性化特征表达能力。“w/o LN”表明,去掉层归一化和丢弃操作后,模型性能出现了显著下降,说明了在xLSTM-LSR中层归一化和丢弃不可缺少,一定程度上减轻了过拟合,提升了模型的鲁棒性。

5.6.2 模型性能与最大序列长度关系分析

本节讨论xLSTM-LSR、基线方法和RNN变种方法的模型性能与长期偏好的最大序列长度(Max Sequence Length)的关系,在LFM-1b数据集上进行实验。为了充分探究模型性能与最大序列长度的关系,我们将长期偏好最大序列长度的最大值设置为1.6k。为了实验的公平,对于不同的最大序列长度,模型训练的训练集、验证集与测试集都是取用户时间最近的交互行为,取不同最大序列长度实验的验证集与测试集是一致的。模型性能与最大序列长度关系的分析如图5所示。通过实验,可以得到以下结论:

(1) 在长期偏好最大序列长度的取值范围为200至1600时,实验结果表明,随着最大序列长度的逐步增加,本文提出的xLSTM-LSR方法性能呈现递增趋势,性能的提升可以归因于从更长的序列能够捕捉更全面和有意义的模式、依赖关系和用户偏好,使xLSTM-LSR能够进行更准确的预测并生成更相关的推荐。然而,推荐系统数据集是真实用户行为数据集,其可能会存在较多的噪声数据,所以,

在最大序列长度达到1400左右以后,提升的幅度较小、基本达到饱和。验证集与测试集是一致的情况下,对较长序列的建模性能优于较短序列,这表明利用较长的历史交互序列能够捕捉更丰富的用户行为模式和潜在偏好,从而提升用户兴趣的表征质量,并提高推荐结果的准确性。然而,尽管建模较长序列可以增强推荐性能,推荐模型在实际应用场景中通常对实时性要求较高,较长的序列长度会显著增加计算资源的消耗,并导致推理时间的显著增长。因此,在推荐系统的实际部署中,需要考虑性能提升与资源开销之间的平衡。

(2) GRU4Rec 随着最大序列长度的增加,其模型性能在最大序列长度达到400后,模型性能基本趋于平稳,不再出现性能增长;LSTM4Rec和BiLSTM4Rec表现出了与GRU4Rec类似的性能表现趋势,说明了基于传统循环神经网络的推荐方法在建模长序列时会受限于长期依赖问题,在解决终身序列任务时能力有限。而基于矩阵与混合长短期记忆网络等新型架构的推荐方法解决长序列任务时性能得到了显著提升,为解决终身长序列推荐任务提供了新思路。Mamba4Rec在处理长序列时同样表现出了随着最大序列长度增加,性能逐步提升的特点,但在处理较短的序列时(例如,长度 ≤ 100),其性能表现不如xLSTM-LSR和SASRec。




图5 模型性能与最大序列长度关系分析实验结果

总体而言, xLSTM-LSR、SASRec、BERT4Rec和Mamba4Rec都是高性能的推荐模型,它们在不同的推荐任务和应用场景中各有优势。在实际的线上推荐系统业务场景中,如果推荐场景主要是面向终身长序列,可以选择xLSTM-LSR和Mamba4Rec;如果业务场景主要是面向短序列,可以选择xLSTM-LSR、SASRec和BERT4Rec;在GPU内存资源受限时,结合5.6.4节的实验结论,可以选择

xLSTM-LSR和Mamba4Rec。

5.6.3 长期偏好权重与最大序列长度关系分析

为了探究长期兴趣建模中最大序列长度对长期偏好权重 α 的影响,本节在LFM-1b和KuaiRand数据集上分别在不同的长期偏好最大序列长度设置下(n 取200、400、600、800、1000、1200、1400和1600),对本文提出的方法xLSTM-LSR通过门控网络得到的长期偏好权重 α 进行实验分析。其中, m 表示

短期偏好的最大序列长度,分别取 $m=10$ 、 $m=20$ 和 $m=30$ 进行实验。图6和图7展示了不同数据集上长期偏好权重 α 随最大序列长度变化的趋势。通过实验,可以得到以下结论:

(1)从整体趋势来看,随着长期偏好最大序列长度 n 的增加,本文提出的方法xLSTM-LSR通过门控网络得到的长期偏好权重 α 在LFM-1b和KuaiRand数据集上均呈现出一定的上升趋势,表明更长的长期行为序列能够为长期兴趣建模提供更丰富的信息,使得门控网络在融合长期与短期偏好时更倾向于赋予长期偏好更高的权重。

(2)然而,长期兴趣偏好占比在不同数据集间存在显著差异,其中,LFM-1b是音乐收听方面的数据

集,KuaiRand是短视频方面的数据集。在LFM-1b数据集上,用户交互序列极长且兴趣相对稳定,增加最大序列长度能够显著提升长期偏好向量的表达能力,因此 α 随长度增加而稳定上升,并在1400左右之后趋于相对平稳。在KuaiRand数据集上,用户兴趣变化频繁,短期上下文信号占主导,即便延长长期窗口, α 也仅呈现轻微上升,且长期权重整体水平仍显著低于在LFM-1b数据集上的长期偏好权重。

(3)对于短期偏好最大序列长度 m 取不同的值(即10、20和30),可以观察到,随着 m 的增加,短期偏好表征能汇聚更多历史短期信号与上下文信息,通常会使模型的门控网络倾向提升短期的相对影响(即降低门控输出的长期偏好权重 α)。




图6 在LFM-1b数据集上长期偏好权重与最大序列长度关系分析实验结果




图7 在KuaiRand数据集上长期偏好权重与最大序列长度关系分析实验结果

5.6.4 模型效率分析

本节分别讨论xLSTM-LSR、基线方法和RNN变种方法的关键的效率指标,包括GPU内存消耗、FLOPs^[48]和推理时间,在ML-1M数据集(长期偏好最大序列长度 $n=150$)上保持相同的超参数设置在RecBole框架^[50]下进行实验。模型效率分析实验结果如表6所示。通过实验,可以得到以下结论:

(1)本文提出的xLSTM-LSR在与基线方法、RNN变种推荐方法的比较中,表现出了最高的性能和较高的效率。而基于Transformer模型的推荐方

法(包括SASRec与BERT4Rec)在处理终身长序列时需要大量的GPU内存资源,在GPU资源受限的环境下,会出现GPU内存不足(Out of Memory)问题,在终身长序列推荐业务场景中,基于Transformer模型的推荐方法会严重依赖于GPU内存资源。考虑到性能与效率之间的平衡,相比SASRec和BERT4Rec,本文提出的xLSTM-LSR能够实现高性能的同时兼顾效率,显著减少了GPU内存和计算开销,在推荐系统这样一个对于实时性要求高的领域,是一种高性价比的解决方案。因此,

我们提出的方法 xLSTM-LSR 在保持较高性能的同时,实现了 GPU 内存和计算开销一定程度的降低,是 GPU 内存资源受限场景下进行终身长序列推荐的一种有效方法。值得注意的是,物品嵌入层作为各类推荐模型中的固定计算开销,因此,相较于同类模型在自然语言处理领域的应用,推荐模型在内存和计算开销上的降低幅度相对受限。

(2)SASRec 和 BERT4Rec 相比基于传统 RNN 的 GRU4Rec,具有显著的性能优势。然而,SASRec 和 BERT4Rec 具有更大的内存和计算开销,在推荐系统这样序列长度相对较短的领域,其并行优势难以充分发挥体现。SASRec 和 BERT4Rec 相比基于 xLSTM 的推荐方法,因为 Transformer 存在二次方计算复杂度的问题,所以,基于 Transformer 的推荐方法相比基于 xLSTM 的推荐方法,需要更大的内存与计算开销。

(3)mLSTM4Rec 相比 GRU4Rec 具有更好的性能,此外它还具有较低的内存开销和推理时间,在有效性和效率之间实现了很好的平衡,说明了矩阵长短期记忆网络相比于传统长短期记忆网络在建模用户偏好方面具有显著的优势。sLSTM4Rec 由于记忆混合无法完全并行计算,但 sLSTM4Rec 有优化的 CUDA 内核支持,同样具有较高的效率。xLSTM-LSR、mLSTM4Rec 和 Mamba4Rec 都支持并行计算,可用于对实时性要求高的大规模终身长序列推荐场景。

表 6 模型效率分析实验结果					
方法	R@10	N@10	GPU 内存	#FLOPs	推理
GRU4Rec	0.2095	0.1061	17.62 GB	19.79 M	0.93x
SASRec	0.2173	0.1109	19.25 GB	23.68 M	1.00x
BERT4Rec	0.2135	0.1081	21.25 GB	25.92 M	1.12x
Mamba4Rec	0.2071	0.1025	16.41 GB	19.61 M	0.79x
sLSTM4Rec	0.2132	0.1053	17.26 GB	21.82 M	0.91x
mLSTM4Rec	0.2357	0.1195	16.95 GB	20.64 M	0.78x
xLSTM4Rec	0.2255	0.1069	18.85 GB	20.92 M	0.95x
xLSTM-LSR	0.2523	0.1340	19.21 GB	21.35 M	0.93x

5.6.5 基于RNN及变种的推荐方法分析

本节讨论 xLSTM-LSR 与本文实现的基于循环神经网络变种的各推荐方法的比较,旨在分析各种 RNN 推荐方法在终身长序列推荐任务上的有效性,在 ML-1M 和 LFM-1b 数据集上进行实验。基于 RNN 及变种的推荐方法分析如表 7 所示。通过实验,可以得到以下结论:

(1)本文提出的 xLSTM-LSR 在 ML-1M 和 LFM-1b 数据集上与 RNN 变种推荐方法的比较中,表现出了最高的性能,说明了 xLSTM-LSR 是一种有效的在终身长序列推荐任务上应用矩阵与混合机制长短期记忆网络的方式。相比基于传统循环神经网络的推荐方法 RNN4Rec、LSTM4Rec 和 BiLSTM4Rec,xLSTM-LSR 具有显著的性能优势,其中 BiLSTM4Rec 将双向长短期记忆网络用于序列推荐,可以同时考虑用户行为序列的正向和反向信息,但在长期依赖问题上依然具有局限性。传统循环神经网络存在梯度消失或梯度爆炸的问题,限制了其在终身长序列建模任务上的能力。相比基于新型循环神经网络的推荐方法 sLSTM4Rec、mLSTM4Rec 和 xLSTM4Rec,xLSTM-LSR 显著优于 sLSTM4Rec 和 xLSTM4Rec,在与 mLSTM4Rec 比较中也表现出性能优势,这一结果验证了 xLSTM-LSR 引入双流机制分别学习用户长期偏好和短期偏好的有效性。

(2)xLSTM-LSR 在 LFM-1b 数据集上的性能提升幅度比在 ML-1M 数据集上的大,说明序列越长,xLSTM-LSR 在建模用户偏好方面的优势越明显,体现出更大的优势。因此,基于矩阵与混合机制双流长短期记忆网络的终身长序列推荐方法能够有效建模用户短期偏好,在建模用户长期偏好上具有更加显著的优势。

表 7 RNN 变种推荐方法比较实验结果				
方法	ML-1M		LFM-1b	
	Recall@10	NDCG@10	Recall@10	NDCG@10
RNN4Rec	0.2005	0.1017	0.2869	0.1920
LSTM4Rec	0.2064	0.1036	0.3365	0.2194
BiLSTM4Rec	0.2102	0.1069	0.3597	0.2312
sLSTM4Rec	0.2132	0.1053	0.3585	0.2290
mLSTM4Rec	0.2302	0.1104	0.3779	0.2505
xLSTM4Rec	0.2255	0.1069	0.3692	0.2389
xLSTM-LSR	0.2523	0.1340	0.3986	0.2713

6 总结和展望

本文提出了一种基于矩阵与混合机制双流长短期记忆网络的终身长序列推荐方法 xLSTM-LSR,这是首次探索新型长短期记忆网络 xLSTM 在终身长序列任务上的应用。xLSTM-LSR 通过矩阵长短期记忆网络模块学习用户的长期兴趣偏好,通过

混合长短期记忆网络模块学习用户的短期兴趣偏好,而后采用门控网络进行长短期偏好的融合,并设计了面向长短期偏好融合的对比学习策略用以增强融合表示的有效性与判别性。在四个数据集上的实验结果与相关分析表明,xLSTM-LSR在排序和召回精度方面相较于基线方法实现了显著提升,同时展现出优越的计算效率与可扩展性。除此之外,我们实现并公开发布了基于循环神经网络的终身长序列推荐的多种变种方法,对循环神经网络在终身长序列推荐问题上可能的特性进行了深入的分析。

在下一步工作中,我们将进一步探索终身长序列推荐任务上的规模扩展法则。除此之外,还将进一步探索更加高效的终身长序列推荐模型,用以建模长度更长的用户行为序列,从而进一步提升终身长序列问题的推荐性能、效率和可扩展性。

致 谢 本文得到国家自然科学基金优秀青年科学基金项目(62222215)、中国科协青年人才托举工程(2023QNRC001)的支持。感谢《计算机学报》编辑部老师和审稿人在审稿过程中提出的宝贵意见。

参 考 文 献

- [1] China Internet Network Information Center. The 55th Statistical Report on China's Internet Development. 2025 (in Chinese) (中国互联网络信息中心. 第55次中国互联网络发展状况统计报告. 2025)
- [2] Tan YK, Xu X, Liu Y. Improved recurrent neural networks for session-based recommendations//Proceedings of the 1st Workshop on Deep Learning for Recommender Systems. Boston, USA, 2016: 17-22
- [3] Li J, Ren P, Chen Z, et al. Neural attentive session-based recommendation//Proceedings of the 2017 ACM on Conference on Information and Knowledge Management. Singapore, 2017: 1419-1428
- [4] Tang J, Wang K. Personalized top-n sequential recommendation via convolutional sequence embedding//Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining. Marina Del Rey, USA, 2018: 565-573
- [5] Yuan F, Karatzoglou A, Arapakis I, et al. A simple convolutional generative network for next item recommendation//Proceedings of the 12th ACM International Conference on Web Search and Data Mining. Melbourne, Australia, 2019: 582-590
- [6] Hidasi B, Karatzoglou A, Baltrunas L., et al. Session-based recommendations with recurrent neural networks. arXiv, 2015: 1511.06939
- [7] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need. Advances in Neural Information Processing Systems, 2017, 30
- [8] Kang WC, Mc Auley J. Self-attentive sequential recommendation//IEEE International Conference on Data Mining. Singapore, 2018: 197-206
- [9] Sun F, Liu J, Wu J, et al. BERT4Rec: Sequential recommendation with bidirectional encoder representations from transformer//Proceedings of the 28th ACM International Conference on Information and Knowledge Management. Beijing, China, 2019: 1441-1450
- [10] Gu A, Dao T. Mamba: Linear-time sequence modeling with selective state spaces. arXiv, 2023: 2312.00752
- [11] Liu C, Lin J, Wang J, et al. Mamba4rec: Towards efficient sequential recommendation with selective state space models. arXiv, 2024: 2403.03900
- [12] Yang J, Li Y, Zhao J, et al. Uncovering selective state space model's capabilities in lifelong sequential recommendation. arXiv, 2024: 2403.16371
- [13] Chang J, Zhang C, Fu Z, et al. TWIN: TWo-stage interest network for lifelong user behavior modeling in CTR prediction at kuaishou//Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Long Beach, USA, 2023: 3785-3794
- [14] Ren K, Qin J, Fang Y, et al. Lifelong sequential modeling with personalized memorization for user response prediction//Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. Paris, France, 2019: 565-574
- [15] Pi Q, Bian W, Zhou G, et al. Practice on long sequential user behavior modeling for click-through rate prediction//Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining. Anchorage, USA, 2019: 2671-2679
- [16] Chen Q, Pei C, Lv S, et al. End-to-end user behavior retrieval in click-through rate prediction model. arXiv, 2021: 2108.04468
- [17] Shen K, Ding X, Zheng Z, et al. Seminar: Search enhanced multi-modal interest network and approximate retrieval for lifelong sequential recommendation. arXiv, 2024: 2407.10714
- [18] Beck M, Pöppel K, Spanring M, et al. xlstm: Extended long short-term memory. Advances in Neural Information Processing Systems, 2024, 37: 107547-107603
- [19] Beck M, Pöppel K, Lippe P, et al. xlstm 7b: A recurrent llm for fast and efficient inference. arXiv, 2025: 2503.13427
- [20] Hochreiter S, and Schmidhuber J. Long short-term memory. Neural Computation, 1997, 9(8): 1735-1780
- [21] Ni J, Li J, McAuley J. Justifying recommendations using distantly-labeled reviews and fine-grained aspects//Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP). Hong Kong, China, 2019: 188-197
- [22] Schedl M. The lfm-1b dataset for music retrieval and recommendation//Proceedings of the 2016 ACM on International Conference on Multimedia Retrieval. New York,

- USA, 2016: 103-110
- [23] Gao C, Li S, Zhang Y, et al. Kuairand: An unbiased sequential recommendation dataset with randomly exposed videos// Proceedings of the 31st ACM International Conference on Information & Knowledge Management. Atlanta, USA, 2022: 3953-3957
- [24] Liu W, Chen C, Liao X, et al. User distribution mapping modelling with collaborative filtering for cross domain recommendation//Proceedings of the ACM Web Conference 2024. Singapore, 2024: 334-343
- [25] Zhang K, Cao Q, Wu Y, et al. Personalized denoising implicit feedback for robust recommender system//Proceedings of the ACM on Web Conference 2025. Sydney, Australia, 2025: 4470-4481
- [26] Zhang J, Xie R, Lu H, et al. Frequency-augmented mixture-of-heterogeneous-experts framework for sequential recommendation// Proceedings of the ACM on Web Conference 2025. Sydney, Australia, 2025: 2596-2605
- [27] Rendle S, Freudenthaler C, Schmidt-Thieme L. Factorizing personalized markov chains for next-basket recommendation// Proceedings of the 19th International Conference on World wide web. Raleigh, USA, 2010: 811-820
- [28] Xie X, Sun F, Liu Z, et al. Contrastive learning for sequential recommendation//2022 IEEE 38th international conference on data engineering (ICDE). Kuala Lumpur, Malaysia, 2022: 1259-1273
- [29] Su J, Chen C, Lin Z, et al. Personalized behavior-aware transformer for multi-behavior sequential recommendation// Proceedings of the 31st ACM International Conference on Multimedia. Ottawa, Canada, 2023: 6321-6331
- [30] Zheng X, Su J, Liu W, et al. DDGHM: Dual dynamic graph with hybrid metric training for cross-domain sequential recommendation//Proceedings of the 30th ACM International Conference on Multimedia. Lisboa, Portugal, 2022: 471-481
- [31] Lin J, Shan R, Zhu C, et al. Rella: Retrieval-enhanced large language models for lifelong sequential behavior comprehension in recommendation//Proceedings of the ACM Web Conference 2024. Singapore, 2024: 3497-3508
- [32] Xi Y, Liu W, Lin J, et al. Towards open-world recommendation with knowledge augmentation from large language models//Proceedings of the 18th ACM Conference on Recommender Systems. 2024: 12-22
- [33] Shu Y, Gu H, Zhang P, et al. Rah! recsys-assistant-human: A human-central recommendation framework with large language models. arXiv, 2023: 2308.09904
- [34] Zhang W, Liu H, Dong Z, et al. Bridging the information gap between domain-specific model and general llm for personalized recommendation//Asia-Pacific Web (APWeb) and Web-Age Information Management (WAIM) Joint International Conference on Web and Big Data. 2024: 280-294
- [35] Zhang J, Xie R, Hou Y, et al. Recommendation as instruction following: A large language model empowered recommendation approach. ACM Transactions on Information Systems, 2025, 43(5): 1-37
- [36] Liu J, Liu C, Zhou P, et al. LLMRec: Benchmarking large language models on recommendation task. arXiv, 2023: 2308.12241
- [37] Dai S, Shao N, Zhao H, et al. Uncovering Chatgpt's capabilities in recommender systems//Proceedings of the 17th ACM Conference on Recommender Systems. Singapore, 2023: 1126-1132
- [38] Yao J, Xu W, Lian J, et al. Knowledge plugins: Enhancing large language models for domain-specific recommendations. arXiv, 2023: 2311.10779
- [39] Qin X, Yuan H, Zhao P, et al. Intent contrastive learning with cross subsequences for sequential recommendation// Proceedings of the 17th ACM International Conference on Web Search and Data Mining. Merida, Mexico, 2024: 548-556
- [40] Yu Y, Gao C, Chen J, et al. EasyRL4Rec: An easy-to-use library for reinforcement learning based recommender systems// Proceedings of the 47th International ACM SIGIR Conference on Research and Development in Information Retrieval. Washington, USA, 2024: 977-987
- [41] Wu L, Zheng Z, Qiu Z, et al. A survey on large language models for recommendation. World Wide Web, 2024, 27(5): 60
- [42] Alkin B, Beck M, Pöppel K, et al. Vision-LSTM: xLSTM as Generic Vision Backbone. arXiv, 2024: 2406.04303
- [43] Alharthi M, Mahmood A. xlstmtime: Long-term time series forecasting with xlstm. AI, 2024, 5(3): 1482-1495
- [44] Kraus M, Divo F, Dhami D.S, et al. Xlstm-mixer: Multivariate time series forecasting by mixing via scalar memories. arXiv, 2024: 2410.16928
- [45] Russakovsky O, Deng J, Su H, et al. Imagenet large scale visual recognition challenge. International Journal of Computer Vision, 2015, 115(3): 211-252
- [46] Yue Z, Wang Y, He Z, et al. Linear recurrent units for sequential recommendation//Proceedings of the 17th ACM International Conference on Web Search and Data Mining. Merida, Mexico, 2024: 930-938
- [47] Li Y, Chen T, Zhang PF, et al. Lightweight self-attentive sequential recommendation//Proceedings of the 30th ACM International Conference on Information & Knowledge Management. Virtual, Queensland, Australia, 2021: 967-977
- [48] Sun W, Liu Z, Fan X, et al. Towards efficient and effective transformers for sequential recommendation//International Conference on Database Systems for Advanced Applications. Tianjin, China, 2023: 341-356
- [49] Krichene W Rendle S. On sampled metrics for item recommendation//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Virtual Event, USA, 2020: 1748-1757
- [50] Zhao WX, Hou Y, Pan X, et al. Recbole 2.0: Towards a more up-to-date recommendation library//Proceedings of the 31st ACM International Conference on Information & Knowledge Management. Atlanta, USA, 2022: 4722-4726



SUN Wen-Qi, Ph. D. candidate.

His main research interests include recommender system, efficient machine learning and large language model.

XIE Ruo-Bing, M. S., researcher. His main research interests include large language model, information retrieval and natural language processing.

ZHANG Jun-Jie, M. S. candidate. His main research

interests include recommender system and large language model.

ZHAO Xin, Ph. D., professor. His main research interests include information retrieval, natural language processing and large language model.

KANG Zhan-Hui, B. S., researcher. His main research interests include large language model and multimodality.

WEN Ji-Rong, Ph. D., professor. His main research interests include Internet big data management, information retrieval and large language model

Background

This work was supported by the National Natural Science Foundation of China No. 62222215 and the Young Elite Scientists Sponsorship Program by China Association for Science and Technology No. 2023QNRC001.

Lifelong sequential recommendation (LSR) aims to learn long-term behavior sequence patterns in chronological order accumulated by users during their utilization within online systems on the Internet. Recently, modeling and understanding long-term user preferences has emerged as a significant research topic in the recommender system (RS) community. Conventional sequential recommendation (SR) approaches mainly focus on short-term behaviors or static preferences, while LSR attempts to understand and predict the evolution of users' behavior patterns and preferences over extended periods, thereby uncovering their long-term user preferences. With the rapid development of short-video platforms and the substantial increase in the length of chronological user behavior sequences (i. e., the number of short videos viewed by users), directly applying existing SR methods to lifelong sequential recommendation tasks presents various limitations. First, Transformer-based SR approaches excel at capturing users' short-term interests and preferences, but face quadratic complexity and high memory consumption with long sequences. Second, Mamba-based methods efficiently capture long-term user behavior dependencies, yet struggle with

accurately modeling short-term preferences. Finally, RNN-based approaches also face challenges, including information forgetting and the inherent gradient vanishing problem associated with RNNs, particularly when dealing with long user behavior sequences.

In this paper, we are motivated to explore the potential application of xLSTM in lifelong sequential recommendation. We implement multiple variants of RNNs and evaluate their capabilities in LSR tasks, and propose a LSR method based on matrix and mixing dual-flow long short-term memory (LSTM) networks, adopting a gating network for the adaptive fusion of long-and short-term preferences, called xLSTM-LSR. This represents the first exploration of the matrix and mixing long short-term memory networks in LSR tasks. xLSTM-LSR first leverages a matrix-based long short-term memory module to model users' long-term preferences, while employing a mixing-based LSTM module to capture their short-term interests. Subsequently, a gating network is introduced to adaptively fuse long-and short-term preferences, and a contrastive learning strategy is further incorporated to enhance both the effectiveness and the discriminability of the fused representations. We conducted extensive experiments and analyses on four public datasets, and the experimental results demonstrate that xLSTM-LSR consistently outperforms baseline methods.