

基于稳定学习的多兴趣序列推荐网络

刘昭呈¹, 朱振熙¹, 刘强^{2*}

(1.北京达佳互联信息技术有限公司,北京 100000;

2.中国科学院自动化研究所 多模态人工智能系统国家重点实验室,北京 100000)

摘要:多兴趣网络以多个表示向量来提取用户多个兴趣,在序列推荐中展现了优秀的表现。然而,用户多个兴趣通常高度相关,模型可能学习到噪声兴趣与目标物品之间的虚假相关性。一旦数据分布变化,兴趣之间的相关性也会改变,虚假相关性将误导模型做出错误预测。为了缓解这个问题,本文提出了一种新的基于稳定学习的多兴趣网络,试图消除模型提取的兴趣之间的相关性,来避免模型捕获虚假相关性。本文采用注意力模块提取多个兴趣,并选择最重要的兴趣进行最终预测。同时,基于独立性准则对训练样本进行加权,以最小化提取到兴趣之间的相关性。本文进行了大量实验显示,在集外(Out-of-Distribution, OOD)和随机设置下,分别取得了36.8%和21.7%的相对提升。

关键词:神经网络;信息检索;推荐系统

中图分类号:TP389.1

文献标志码:A

文章编号:0253-2395(2024)03-0471-10

Sequential Recommendation of Multi-Interest Network Based on Stable Learning

LIU Zhaocheng¹, ZHU Zhenxi¹, LIU Qiang^{2*}

(1.Kuaishou Technology, Beijing 100000, China;

2.Center for Research on Intelligent Perception and Computing, State Key Laboratory of Multimodal Artificial Intelligence Systems, Institute of Automation, Chinese Academy of Sciences, Beijing 100000, China)

Abstract: Multi-interest models, which extract interests of a user as multiple representation vectors, have shown promising performances for sequential recommendation. However, considering that multiple interests of a user are usually highly correlated, the model has chance to learn spurious correlations between noisy interests and target items. Once the data distribution changes, the correlations among interests may also change, and the spurious correlations will mislead the model to make wrong predictions. To solve such problem, we propose a novel model of Multi-Interest network with Stable Learning (MISL), which attempts to de-correlate the extracted interests, and thus spurious correlations can be eliminated. MISL applies an attentive module to extract multiple interests, and then selects the most important one for making final predictions. Meanwhile, MISL incorporates a weighted correlation estimation loss based on independence criterion, with which training samples are weighted, to minimize the correlations among extracted interests. Extensive experiments have been conducted under both Out-of-Distribution (OOD) and random settings, and up to 36.8% and 21.7% relative improvements are achieved respectively.

Key words: neural networks; information retrieval; recommendation system

收稿日期:2023-12-15;接受日期:2024-01-12

基金项目:国家自然科学基金(62206291)

作者简介:刘昭呈(1993-),男,山东枣庄人,算法工程师,研究方向为应用机器学习。E-mail:lio.h.zen@gmail.com

* 通信作者:刘强(LIU Qiang),E-mail:qiang.liu@nlpr.ia.ac.cn

引文格式:刘昭呈,朱振熙,刘强.基于稳定学习的多兴趣序列推荐网络[J].山西大学学报(自然科学版),2024,47(3):471-480. DOI:10.13451/j.sxu.ns.2024004

0 引言

序列推荐旨在基于历史交互来预测用户下一个感兴趣的物品,是推荐系统的一个重要研究领域,在电商和短视频等场景发挥着关键作用。为了准确捕获用户的行为交互序列,之前的工作^[1-5]将各种神经网络模块引入到序列推荐任务中,包括:循环神经网络(Recurrent Neural Networks, RNN)、卷积神经网络(Convolutional Neural Networks, CNN)和注意力网络(Attentive Networks)等。

通常,用户会有多个兴趣,比如,用户在短视频平台上,会同时喜欢看关于足球、搞笑和汽车的视频。为了实现精准的序列推荐,我们需要捕获用户的多个兴趣,多兴趣网络^[6-8]应运而生。具体来说,多兴趣网络是采用多个表示向量来建模用户天然多个兴趣。然而,现有的多兴趣网络忽视了系统中的兴趣分布是一直在变化的。这会给多兴趣网络带来集外(Out-of-Distribution, OOD)泛化问题^[9-12]。集外泛化问题会不可避免地损害多兴趣网络在实际应用时的表现。为了清晰地说明多兴趣模型中的集外泛化问题,本文做如下3点定义:

稳定兴趣:给定一个目标物品和一个用户历史行为过的物品序列,稳定兴趣是序列中与目标物品具有因果关系的物品集合。

噪声兴趣:给定一个目标物品和一个用户历史行为过的物品序列,噪声兴趣是序列中与目标物品没有因果关系的物品集合。

虚假相关性:多兴趣网络拟合训练样本时,错误地学习到目标物品与噪声兴趣之间存在相关性。

现今产品的交互设计下,用户所见多数取决于模型和策略,这会导致用户历史行为过的物品之间存在依赖,进而导致现有模型捕获到的(稳定/噪声)兴趣之间会存在一定依赖。具体来说,对于给定物品而言,有因果关系的物品和没有因果关系的物品,在一个时间片内,可能总是一起曝光,导致现有的多兴趣模型认为这两种物品均与目标物品存在很强的相关性,造成按照本文定义下,现有模型下,稳定兴趣和噪声兴趣之间会存在一定依赖。这种依赖可能会让现有的多兴趣网络捕获到虚假相关

性。如果稳定兴趣与噪声兴趣之间的依赖是稳定的,则不会造成任何问题。但不幸的是,实际应用中推荐模型和运营策略都会尽可能实时拟合热点变化,导致用户行为历史中的物品之间依赖不断变化,进而导致稳定兴趣与噪声兴趣之间的依赖是非常脆弱的。因此,当多兴趣网络过多地捕获了虚假相关性时,在实际应用中会存在预估不稳定的问题,这就是序列推荐中的集外泛化问题,对应的因果分析如图1所示。




图1 多兴趣序列推荐模型的因果分析

(a) 现有模型的因果图;(b) 本文提出的方法目标为消除稳定兴趣与噪声兴趣之间的依赖性

Fig. 1 Causal analysis of multi-interest sequence recommendation models

(a) Causal diagram of previous work; (b) the method proposed in this paper aims to eliminate the dependency between stable interests and noisy interests

为了缓解多兴趣序列推荐模型的集外泛化问题,最直接的方案是消除稳定兴趣和噪声兴趣之间的依赖,进而限制模型去学习稳定兴趣与目标物品之间的因果关系。为了实现这一点,可以采用逆倾向加权(Inverse Propensity Weighting, IPW)^[13-14]。然而,倾向分非常难以预估且存在较大的预估方差^[15]。同时,一些工作尝试构造反事实样本(Counterfactual Sample)来训练因果模型^[10],但是,构造的反事实样本的质量难以把控。另外,给定目标物品,区分模型捕获的所有兴趣里哪些是稳定兴趣,哪些是噪声兴趣是非常困难的,这造成精准消除稳定兴趣与噪声兴趣之间的依赖是极端困难的。为了解决这些难题,本文从稳定学习^[16-18]汲取经验,选择去消除模型捕获的所有兴趣之间的依赖。为了实现这一点,本文采取了一种可以与主损失目标一起被优化的相关性估计损失。

本文提出了一种新的基于稳定学习的多兴趣网络(Multi-Interest network with Stable Learn-

ing, MISL)。本文基于注意力网络建立多兴趣提取器来从用户行为历史提取多兴趣表达,并选取最重要的一个作为用户的表达,来进行预估并构建训练的主损失目标。同时,本文采用希尔伯特-施密特独立性准则(Hilbert-Schmidt Independence Criterion, HSIC)^[19-20]来估计提取到的兴趣之间的相关度。希尔伯特-施密特独立性准则是一种被广泛应用的非线性独立性检验统计量,已经被用来做特征的去相关^[21]。MISL给每个训练样本增加一个可学习的样本权重,初始化为1,训练时最小化捕获兴趣之间的相关度来更新样本权重的大小。同时,样本权重对应作用到主损失目标上,作为每条训练样本的权重,来影响模型参数的更新。当捕获兴趣之间的相关度较高时,样本权重会较低,反之亦然。最小化兴趣之间的相关度和样本权重加权后的主目标损失,是交替优化直至收敛。如此,兴趣相关度本身较低的样本会对模型参数的影响显著更大,从而减少兴趣之间的依赖对模型训练的干扰,让模型学到更多稳定兴趣与目标物品之间的因果关系,而不是噪声兴趣与目标物品之间的虚假相关性。我们在三个公开数据集上,基于集外和随机两种实验设置,进行了详细的实验。在这些实验中,MISL均取得了优秀的表现。

本文的其余部分组织如下。第1节回顾了关于序列推荐、多兴趣模型和稳定学习的相关工作。第2节介绍本文提出的MISL模型。在第3节介绍我们的实验设置和实验结果。最后第4节对本文进行了总结。

1 相关工作

在本节中,本文回顾了关于序列推荐、多兴趣网络和稳定学习的相关工作。

1.1 序列推荐

建模用户动态偏好是序列推荐研究的核心,也是推荐系统的主要任务。一些传统的序列推荐模型^[22-25],采用马尔科夫链(Markov Chain)和矩阵分解(Matrix Factorization)来建模历史行为。最近几年,诸如循环神经网络、卷积神经网络和注意力网络等深度神经网络已经被广泛引入到序列推荐任务中^[1-5, 26-27]。除了

引入深度神经网络,类似对比学习等深度学习范式也已经被应用到序列推荐中^[28-29]。同时,也有一些工作尝试利用更多的辅助信息(Side Information)来挖掘信息增益^[30-31]。另外,序列推荐中的偏差问题,比如曝光偏差,也得到了研究^[32-33]。最后,还有一些工作在用户行为历史中生成反事实样本来缓解集外泛化问题^[10, 34]。

1.2 多兴趣网络

一个用户表示向量无法表达用户天然存在的多样兴趣。基于动态路由的多兴趣网络(Multi-Interest Network with Dynamic routing, MIND)^[6]首次提出了序列推荐中的多兴趣抽取器。由于动态路由可以看作软聚类,因此用户的行为会被分组到不同的簇。在此基础上,一种可控多兴趣框架^[7]被提出,在此框架中,动态路由和注意力模型都可以被用来抽取用户的多个兴趣表示。最近,有一些工作^[35]会直接维护一个概念原型池,使用注意力机制来决定哪些原型与用户的多个兴趣关联。另一些工作^[8]则将多兴趣学习与图卷积网络(Graph Convolutional Networks, GNN)结合起来,通过聚合多层次的用户偏好,来更精确地提取用户的多个兴趣。

1.3 稳定学习

稳定学习是处理实际应用常见的集外泛化问题^[9]的一种有效手段。稳定学习旨在学习一个稳定的预测模型,在任何未知的测试数据上均能达到均匀良好的性能^[17]。大多数稳定学习可以分为两个步骤:样本权重学习和加权训练。针对线性稳定模型,各种各样的学习样本权重的方法已经被提出^[16-18]。稳定网络(StableNet)^[36]提出采用随机傅里叶特征(Random Fourier Features)来消除卷积神经网络中特征之间的非线性依赖。另外,一些稳定学习工作^[37-39]研究了图神经网络和健康管理中的特征去相关。最近,理论上证明,在温和条件下,通过特征变量之间的相互独立性,可以保证最小二乘回归和二元分类的稳定性^[40]。

2 提出的方法

本文提出方法的概览如图2所示,在本节

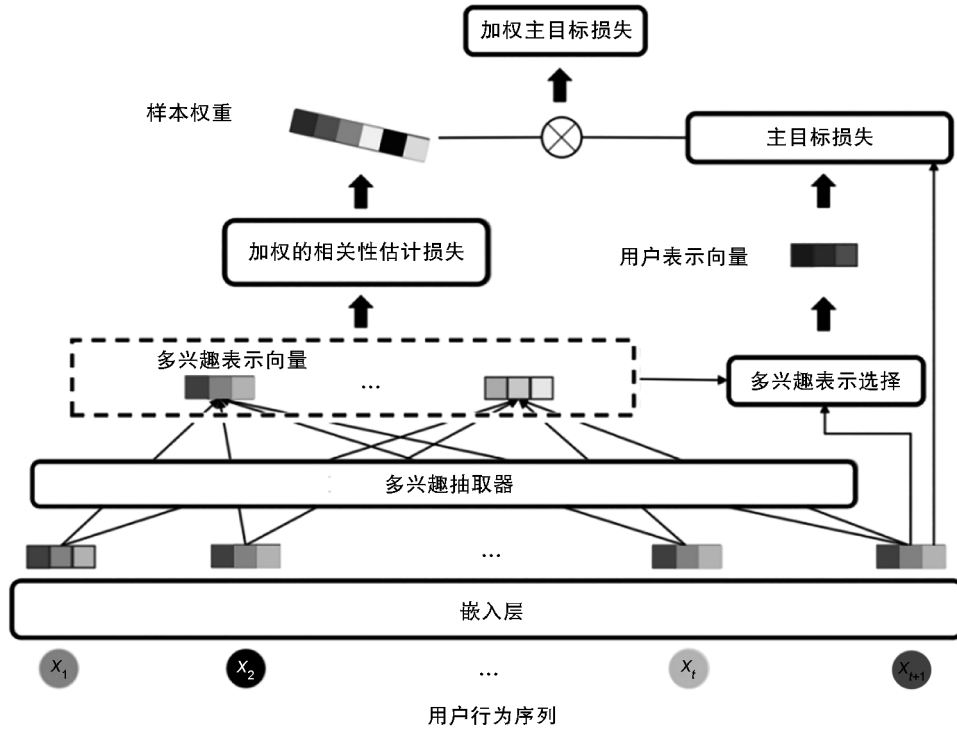


图2 本文提出方法的架构概览

注:我们提出方法的概览:用户行为序列经过嵌入层映射后,由多兴趣抽取器抽取多个兴趣表示向量,选择最重要的那个表示向量作为用户表示参与主目标损失构建。同时,通过加权的相关性估计损失,来更新样本权重,后者会用于主目标损失的加权。加权后的主目标损失才会对模型参数进行更新。

Fig. 2 The overall architecture of our proposed MISL

Note: Overview of our proposed method: After mapping user behavior sequences through an embedding layer, multiple interest extractors are employed to extract multiple interest representation vectors. The most significant representation vector is selected as the user representation and is used in the construction of the main objective loss. Simultaneously, a weighted correlation estimation loss is utilized to update sample weights, which are then applied as weights to the main objective loss. Only after being weighted, does the main objective loss update the model parameters.

中,本文给出了问题的公式化表述,并且详细介绍了本文提出的方法。

2.1 问题的公式化表述

一般来说,在序列推荐的设置中,存在一个用户的集合 $U = \{u_1, u_2, \dots, u_{|U|}\}$ 和一个物品的集合 $I = \{i_1, i_2, \dots, i_{|I|}\}$ 。对于用户 u ,其截止到时刻 t 的行为序列 $X^u = \{x_1^u, x_2^u, \dots, x_t^u\}$,序列推荐的目标是预估这个用户下一次交互 x_{t+1}^u ,其中 $x_t^u \in I$ 。序列推荐的目标是给每个用户推荐一个物品的列表以最大化满足该用户的未来需求。同时,本文使用 c 来表示多兴趣模型中兴趣表示向量的个数。

2.2 多兴趣表达抽取

首先,通过嵌入层(Embedding Layer)将用户行为序列映射成向量表示。具体来说,给定用户 u 的行为序列 X^u ,通过对嵌入矩阵(Em-

bedding Matrix) $V \in R^{n \times d}$ (其中 d 为嵌入表示的维度)进行 look-up 操作,来获取嵌入层的映射结果。另外,为了感知行为序列中每个物品的出现位置,可以在嵌入层注入可学习的位置嵌入矩阵^[4] $P \in R^{t \times d}$ 。最终嵌入层的输出为 $E_t^u \in R^{t \times d}$,可以公式化表示为:

$$E_t^u = \begin{bmatrix} V_{x_1^u} + P_1 \\ \vdots \\ V_{x_t^u} + P_t \end{bmatrix} \quad (1)$$

在多兴趣抽取上,由于本文的重点不在于设计更好的多兴趣抽取器,因此,我们经验性地采取了一个简单的注意力模块来作为多兴趣抽取器。注意力矩阵 $A_t^u \in R^{c \times t}$ 可以按照如下来计算:

$$A_t^u = \text{softmax}(W_2 \tanh(W_1(E_t^u)^T)), \quad (2)$$

其中, $W_1 \in R^{d \times d}$ 和 $W_2 \in R^{c \times d}$ 都是可学习的转移矩阵。如此, c 个多兴趣表达向量 $M_i^u \in R^{c \times d}$ 可以如下得到:

$$M_i^u = A_i^u E_i^u. \quad (3)$$

至此, 针对每个用户, 可以得到 c 个表示向量来捕获用户的多个兴趣。

进一步地, 采用兴趣选择策略^[7]来从捕获到的兴趣表达中选择最重要的兴趣表达, 作为用户行为序列的表达。给定要预估的物品 x_{t+1}^u 的嵌入式表达 $V_{x_{t+1}^u}$, 最重要的兴趣表达 $R_t^u \in R^{1 \times d}$ 可以按照如下选出:

$$R_t^u = M_i^u [\operatorname{argmax}(M_i^u V_{x_{t+1}^u}^T), :]. \quad (4)$$

最终, 针对从训练集中采样的一个批样本 β , 不加权的主目标损失可以定义为:

$$L_{\text{main}} = - \sum_{(u,t) \in \beta} \log \left(\frac{\exp(R_t^u V_{x_{t+1}^u}^T)}{\sum_{i \in I} \exp(R_i^u V_i^T)} \right). \quad (5)$$

考虑到计算效率, 公式(5)可以借助采样 Softmax^[41-42]来实现。

2.3 多兴趣表达之间去相关

由于给定目标物品, 区分哪些是稳定兴趣, 哪些是噪声兴趣是十分困难的。本文受到稳定学习的工作^[16-18, 36]启发, 选择通过样本加权来实现对所有兴趣去相关。也就是说, 估计每一对兴趣之间的相关度, 并通过优化样本权重来最小化所有样本的每一对兴趣的相关度之和。通常, 兴趣之间的相关度是非线性的, 本文选用应用广泛的希尔伯特-施密特独立性准则^[19-20]。

具体来说, 针对每条样本指定一个样本权重 $\omega_{u,t}$ 。本文使用 $\omega_{u,t}^{(q)}$ 表示经过第 q 轮训练更新后的样本权重, 同时初始的样本权重表示为 $\omega_{u,t}^{(0)} = 1.0$ 。在第 q 轮训练时, 先将样本权重按照如下作用到多兴趣表达上:

$$\hat{M}_{u,t}^{(q)} = \omega_{u,t}^{(q-1)} M_i^u. \quad (6)$$

然后, 将样本权重作用后的多兴趣表达, 构建成多个兴趣对, 借助希尔伯特-施密特独立性准则对每个兴趣对的相关度进行估计并求和:

$$L_{\text{corr}}^{(q)} = \sum_{(u,t) \in \beta} \sum_{j,k} \gamma \text{HSIC}(\hat{M}_{u,t}^{(q-1)}[j, :], \hat{M}_{u,t}^{(q-1)}[k, :]), \quad (7)$$

其中, γ 是去相关系数用于控制样本权重的学

习。然后, 通过优化样本权重来最小化兴趣对的相关度之和:

$$\omega_{\beta}^{(q)} = \operatorname{argmin}_{\omega} L_{\text{corr}}^{(q)}, \quad (8)$$

将 $\omega_{\beta}^{(q)}$ 用来加权主目标损失:

$$\hat{L}_{\text{main}}^{(q)} = - \sum_{(u,t) \in \beta} \omega_{u,t}^{(q)} \log \left(\frac{\exp(R_t^u V_{x_{t+1}^u}^T)}{\sum_{i \in I} \exp(R_i^u V_i^T)} \right). \quad (9)$$

最后, 本文在每一轮训练时, 更新样本权重和利用更新后的样本权重对主目标损失加权来更新模型参数, 是交替进行直至收敛的。

3 实验

在本节中, 介绍为了验证提出的 MISL 表现而进行的实验。主要关心如下几个研究问题:

- MISL 在集外设置下的表现如何?
- MISL 在集内 (in-distribution) 设置下的表现如何?
- MISL 的样本加权如何影响多兴趣网络的收敛过程?
- MISL 最终收敛的样本权重的分布是什么样的?

3.1 实验数据集

本文在两个经典的序列推荐公开数据集上进行了实验:

● 书评数据集: 书评数据集来自亚马逊产品评论数据集。一共有 603 668 个用户, 367 982 个物品和 8 898 041 条用户行为。

● 影评数据集: 影评数据集同样来自亚马逊评论数据集。一共有 304 763 个用户, 89 590 个物品和 3 506 470 条用户行为。

同时, 本文对以上数据集有两种切分方式:

● 集外切分: 在离线实验的设置下, 本文根据不同的用户组来构建集外数据集。具体来说, 使用来自不同用户行为过的物品的杰卡得相似度 (Jaccard similarity), 来度量用户之间的相似度。本文会先随机选择一个用户, 然后选择与这个用户最像的用户, 不断迭代, 直到选中了 50% 的用户。这样选中的用户和未被选中的用户存在显著分布偏差。最终, 选中用户的 10%, 未选中用户的 10% 和未选中用户的剩余部分分别作为测试集, 验证集和训练集。

● 集内切分: 本文遵循之前工作中的随机切分作为集内切分。

3.2 基线模型

本文为了验证 MISL 的表现,对比了如下基线模型:

● GRU4Rec^[43]:基于循环神经网络的经典序列推荐模型。

● SASRec^[4]:基于自注意力网络(self-attention network)的序列推荐 SOTA (State-of-the-art)。

● MIND^[6]:使用动态路由的经典多兴趣网络。

● ComiRec^[7]:带有多兴趣抽取器的序列推荐。具体来说,本文使用原文中 ComiRec-SA 这一设置。

● SINE^[35]:维护了兴趣概念原型池的多兴趣网络,并且使用自注意力去决定哪些原型匹配用户多兴趣。

● MGNM^[8]:结合图卷积网络的多兴趣网络。

● CRec (CauseRec)^[10]:基于对比学习建模反事实数据分布的序列推荐 SOTA。

MISL 与上述模型在集外和集内两个设置都做了对比。另外,本文额外增加了基于逆倾向加权的排序加权(Permutation Weighting, PW),将 PW 作用到 ComiRec 和 MGNM 上得到 ComiRec+PW 和 MGNM+PW,用于集外对比。

3.3 评测指标

本文使用召回率(Recall)、归一化打折累计提升(Normalized Discounted Cumulative Gain, NDCG)和命中率(Hit Rate, HR)来评估所有对比方法的效果。这三个指标评估了模型不同方面的效果。在具体指标计算中,需要对推荐物品列表进行截断,本文选用前 50 名来做截断。

3.4 集外实验结果

集外实验结果如表 1 所示。

从表 1 可知,首先,在所有的基线模型中,CRec 表现最好,在 6 个指标中 4 个表现最好。多兴趣网络中,MIND 和 ComiRec 这两个多兴趣网络效果相对较好。这代表结构相对简单的模型在集外设置下表现会相对较好。同时,我们提出的 MISL 在所有的六个指标上,相比所有的基线模型,取得了最好的效果。

同时,集外数据上,MISL 对比 ComiRec+PW 和 MGNM+PW 的结果如表 2 所示。从表 2 可知,在基线模型中,ComiRec+PW 在书评数据集上表现更好,MGNM+PW 则在影评数据集上表现更好。如果与表 1 中对应数据做对比的话,ComiRec+PW 和 MGNM+PW 均比 ComiRec 和 MGNM 各自要好。

这进一步揭示了逆倾向加权对于缓解集外泛化问题有效果。最后,从表 2 可知,本文提出的方法 MISL 效果是最好的。

表 1 集外数据上的实验结果

Table 1 The experimental results on the out-of-distribution data

| 模型 | 书评数据集 | | | 影评数据集 | | |
|---------|--------------|-------------|--------------|--------------|--------------|--------------|
| | Recall | NDCG | HR | Recall | NDCG | HR |
| GRU4Rec | 5.84 | 3.15 | 12.10 | 14.08 | 11.85 | 25.20 |
| SASRec | 6.78 | 3.54 | 13.56 | 15.01 | 12.72 | 26.35 |
| MIND | 7.10 | 4.00 | 15.99 | 16.18 | 13.54 | 28.56 |
| ComiRec | <u>8.01</u> | 3.78 | 15.86 | 16.57 | 13.92 | 29.84 |
| SINE | 7.56 | <u>4.22</u> | 15.84 | 16.68 | 13.77 | 29.71 |
| MGNM | 7.35 | 4.15 | 15.74 | 17.17 | 13.76 | 29.75 |
| CRec | 7.71 | 4.08 | <u>16.04</u> | <u>17.33</u> | <u>14.40</u> | <u>30.05</u> |
| MISL | 10.98 | 5.30 | 18.27 | 18.65 | 15.44 | 31.02 |

注:所有指标均只保留四位有效数字,表中为百分数。最好的基线模型效果采用下划线标出,最强的效果采用粗体标出。

表 2 集外数据上的补充实验结果(对比排序加权)

Table 2 Supplementary experimental results on out-of-distribution data (in comparison to permutation weighting)

| 模型 | 书评数据集 | 影评数据集 |
|------------|--------------|--------------|
| ComiRec+PW | 8.63 | 17.16 |
| MGNM+PW | 8.14 | 17.54 |
| MISL | 11.09 | 18.49 |

注:集外数据上,MISL 对比 ComiRec+PW 和 MGNM+PW,为了保持简洁,指标仅保留 Recall@50。最好的效果采用粗体标出。

3.5 集内实验结果

集内(即,随机切分)的实验结果如表 3 所示。

对比表 1 和表 3 可知,表 1 中对应的结果均低于表 3,这说明集外导致的分布变化让任务变得更难,削弱了模型效果。但看表 3 结果可知,基于注意力的 SASRec 表现好于基于循环神经网络的 GRU4Rec,多兴趣网络的表现则比他们都要好。在图卷积神经网络的加持下,MGNM 是所有多兴趣网络中表现相对较好的。同时,本文提出的方法在所有指标上都显著优

表3 集内数据上的实验结果

Table 3 The experimental results on the in-distribution data

| 模型 | 书评数据集 | | | 影评数据集 | | |
|---------|--------------|-------------|--------------|--------------|--------------|--------------|
| | Recall | NDCG | HR | Recall | NDCG | HR |
| GRU4Rec | 6.50 | 4.42 | 12.38 | 17.66 | 16.21 | 29.54 |
| SASRec | 7.78 | 5.74 | 13.79 | 18.27 | 16.72 | 30.43 |
| MIND | 7.64 | 5.97 | 15.56 | <u>19.55</u> | <u>17.23</u> | 32.93 |
| ComiRec | 9.35 | 5.47 | 18.04 | 18.87 | 16.17 | 33.68 |
| SINE | 8.72 | 6.04 | 18.94 | 19.30 | 16.64 | 33.30 |
| MGNM | <u>9.64</u> | 6.19 | <u>20.22</u> | 19.14 | 16.68 | <u>33.95</u> |
| CRec | 9.36 | <u>6.28</u> | <u>20.23</u> | 19.24 | 16.83 | 33.90 |
| MISL | 11.06 | 7.24 | 21.53 | 20.98 | 17.36 | 34.91 |

注:所有指标均只保留四位有效数字,表中为百分数。最好的基线模型效果采用下划线标出,最强的效果采用粗体标出。

于基线模型。同时,对比表1和表3的相关数据可知,在集外设置下,相比于最强基线效果,MISL带来的提升比例是更高的。

3.6 可视化

在图3中,本文将MISL和ComiRec训练时,训练集上的兴趣之间的希尔伯特-施密特独立性准则的变化,和验证集上召回率的变化,做了可视化。

可以看到两个方法都采用早停策略(Early Stopping),并且停在了不同的迭代数上,这造成图中的线是不等长的。在前10 000步中,独立性准则和召回率都在急速增加。接着,ComiRec的独立性准则继续急速增加,同时MISL的却增加相对缓慢。这让MISL去更新更多迭代数成为可

能,并且带来了更好的效果。

另外,在图4中,本文用直方图的形式展示了MISL在书评数据集上学到的样本权重的分布。从图中可知,绝大部分样本权重都位于0.8到1.0之间,代表对对应样本的主目标损失进行轻微的降权。同时,可以看到有一部分样本权重在0附近,代表对应的训练样本的主目标损失被显著降权。综上,这代表了书评数据集中大部分样本不需要太多去相关操作,但是有小部分样本存在较为严重的依赖,需要显著降权。

4 结论

针对精确稳定地序列推荐,本文调研了多兴趣网络的集外泛化问题。本文提出了一种新的多兴趣推荐模型,命名为MISL。MISL使用注意力模块来抽取多个兴趣,并且挑选最重要的一个用于预估值计算。然后,结合一个加权的相关性估计损失,来缓解训练集中捕获的不同兴趣之间的依赖。如此来实现稳定表达的学习,在集外环境中保持预估的稳定性。在集外和集内两个设置下,进行了充分的实验,验证了MISL的有效性。另外,关于样本权重的优化如何动态影响多兴趣模型的兴趣捕获,我们仍在探索中,进一步地,推荐的可解释性也是重要方向,当可解释性做得足够好时,更有利于深刻理解集外泛化问题,在实际应用中带来

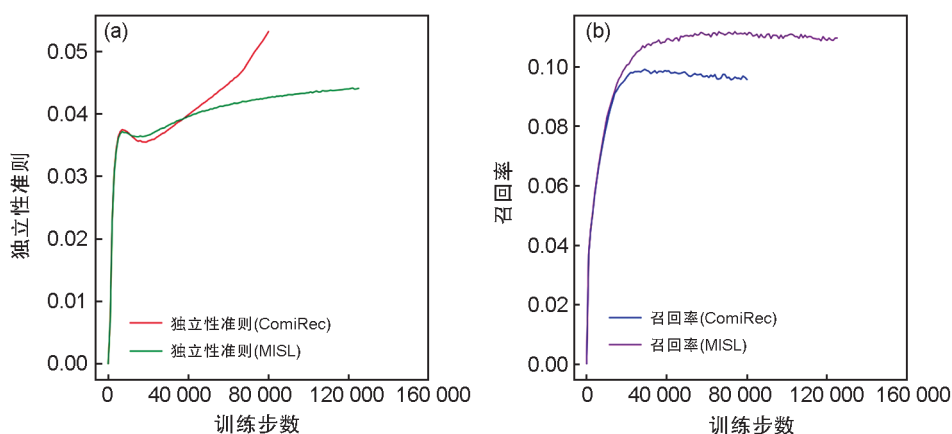


图3 书评训练集上兴趣独立性准则与验证集上召回率的变化趋势

(a) 训练集上兴趣之间的希尔伯特-施密特独立性准则;(b) 验证集上召回率

Fig. 3 Trends in the Hilbert-Schmidt Independence Criterion between interests on the training set of book reviews and the change in recall rate on the validation set

(a) The Hilbert-Schmidt Independence Criterion (HSIC) between interests on the trainingset; (b) recall rate on the validation set




图4 MISL在书评数据集训练出的样本权重分布

Fig. 4 The sample weight distribution trained by MISL on the book review dataset

的影响,也更有利于进一步解决该问题。

参考文献:

- [1] YU F, LIU Q, WU S, *et al.* A Dynamic Recurrent Model for Next Basket Recommendation[C]//Proceedings of the 39th International ACM SIGIR conference on Research and Development in Information Retrieval. Pisa: ACM, 2016: 729–732. DOI: 10.1145/2911451.2914683.
- [2] TANG J X, WANG K. Personalized Top-N Sequential Recommendation *via* Convolutional Sequence Embedding [C]//Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining. Marina Del Ray: ACM, 2018: 565–573. DOI: 10.1145/3159652.3159656.
- [3] LIU Q, ZENG Y F, 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. London: ACM, 2018: 1831–1839. DOI: 10.1145/3219819.3219950.
- [4] KANG W C, MCAULEY J. Self-attentive Sequential Recommendation[C]//2018 IEEE International Conference on Data Mining (ICDM). Singapore: IEEE, 2018: 197–206. DOI: 10.1109/ICDM.2018.00035.
- [5] 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. Beijing: ACM, 2019: 1441–1450. DOI: 10.1145/3357384.3357895.
- [6] LI C, LIU Z Y, WU M M, *et al.* Multi-interest Network with Dynamic Routing for Recommendation at Tmall[C]//Proceedings of the 28th ACM International Conference on Information and Knowledge Management. Beijing: ACM, 2019: 2615–2623. DOI: 10.1145/3357384.3357814.
- [7] CEN Y K, ZHANG J W, ZOU X, *et al.* Controllable Multi-interest Framework for Recommendation[C]//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM, 2020: 2942–2951. DOI: 10.1145/3394486.3403344.
- [8] TIAN Y, CHANG J X, NIU Y N, *et al.* When Multi-level Meets Multi-interest: a Multi-grained Neural Model for Sequential Recommendation[C]//Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. Madrid: ACM, 2022: 1632–1641. DOI: 10.1145/3477495.3532081.
- [9] LIU J S, SHEN Z Y, HE Y, *et al.* Towards Out-of-distribution Generalization: A Survey[EB/OL]. arXiv Preprint: 2108.13624, 2021. <https://doi.org/10.48550/arXiv.2108.13624>.
- [10] ZHANG S Y, YAO D, ZHAO Z, *et al.* CauseRec: Counterfactual User Sequence Synthesis for Sequential Recommendation[C]//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2021: 367–377. DOI: 10.1145/3404835.3462908.
- [11] YANG C X, WU Q T, WEN Q S, *et al.* Towards Out-of-Distribution Sequential Event Prediction: A Causal Treatment[J]. *Adv Neural Inf Process Syst.* 2022, **35**: 22656–22670.
- [12] YANG Z Y, HE X N, ZHANG J Z, *et al.* A Generic Learning Framework for Sequential Recommendation with Distribution Shifts[C]//Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval. Taipei: ACM, 2023: 331–340. DOI: 10.1145/3539618.3591624.
- [13] ARBOUR D, DIMMERY D, SONDH I A. Permutation Weighting[EB/OL]. arXiv Preprint: 1901.01230, 2021. <https://doi.org/10.48550/arXiv.1901.01230>.
- [14] WANG Z L, SHEN S Q, WANG Z P, *et al.* Unbiased Sequential Recommendation with Latent Confounders[C]//Proceedings of the ACM Web Conference 2022. New York: ACM, 2022: 2195–2204. DOI: 10.1145/3485447.3512092.
- [15] ZHANG Y, FENG F L, HE X N, *et al.* Causal Intervention for Leveraging Popularity Bias in Recommendation [C]//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2021: 11–20. DOI: 10.1145/3404835.3462875.
- [16] SHEN Z Y, CUI P, ZHANG T, *et al.* Stable Learning via Sample Reweighting[J]. *Proc AAAI Conf Artif Intell*, 2020,

- 34(4): 5692–5699. DOI: 10.1609/aaai.v34i04.6024.
- [17] KUANG K, CUI P, ATHEY S, *et al.* Stable Prediction across Unknown Environments[C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM, 2018: 1617–1626. DOI: 10.1145/3219819.3220082.
- [18] KUANG K, XIONG R X, CUI P, *et al.* Stable Prediction with Model Misspecification and Agnostic Distribution Shift[C]//Proceedings of the AAAI Conference on Artificial Intelligence. New York: ACM, 2020, 34(4): 4485–4492. DOI: 10.1609/aaai.v34i04.5876.
- [19] GRETTON A, BOUSQUET O, SMOLA A, *et al.* Measuring Statistical Dependence with Hilbert-Schmidt Norms[M]//Lecture Notes in Computer Science. Berlin, Heidelberg: Springer Berlin Heidelberg, 2005: 63–77. DOI: 10.1007/11564089_7.
- [20] GRETTON A, FUKUMIZU K, TEO C H, *et al.* A Kernel Statistical Test of Independence[C]//Proceedings of the 20th International Conference on Neural Information Processing Systems. New York: ACM, 2007: 585–592. DOI: 10.5555/2981562.2981636.
- [21] BAHNG H, CHUN S, YUN S, *et al.* Learning Debaised Representations with Biased Representations [EB/OL]. arXiv Preprint: 1910.02806, 2019. <https://doi.org/10.48550/arXiv.1910.02806>.
- [22] 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. New York: ACM, 2010: 811–820. DOI: 10.1145/1772690.1772773.
- [23] HE R N, MCAULEY J. Fusing Similarity Models with Markov Chains for Sparse Sequential Recommendation [C]//2016 IEEE 16th International Conference on Data Mining (ICDM). Barcelona: IEEE, 2016: 191–200. DOI: 10.1109/ICDM.2016.0030.
- [24] HE R N, KANG W C, MCAULEY J. Translation-based Recommendation[C]//Proceedings of the Eleventh ACM Conference on Recommender Systems. New York: ACM, 2017: 161–169. DOI: 10.1145/3109859.3109882.
- [25] HIDASI B, TIKK D. General Factorization Framework for Context-aware Recommendations[J]. *Data Min Knowl Discov*, 2016, 30(2): 342–371. DOI: 10.1007/s10618-015-0417-y.
- [26] WANG J Y, LIU Q, LIU Z C, *et al.* Towards Accurate and Interpretable Sequential Prediction: A CNN & Attention-based Feature Extractor[C]//Proceedings of the 28th ACM International Conference on Information and Knowledge Management. New York: ACM, 2019: 1703–1712. DOI: 10.1145/3357384.3357887.
- [27] LI J C, WANG Y J, MCAULEY J. Time Interval Aware Self-attention for Sequential Recommendation[C]//Proceedings of the 13th International Conference on Web Search and Data Mining. New York: ACM, 2020: 322–330. DOI: 10.1145/3336191.3371786.
- [28] ZHOU K, WANG H, ZHAO W X, *et al.* S3-rec: Self-supervised Learning for Sequential Recommendation with Mutual Information Maximization[C]//Proceedings of the 29th ACM International Conference on Information & Knowledge Management. New York: ACM, 2020: 1893–1902. DOI: 10.1145/3340531.3411954.
- [29] CHEN Y J, LIU Z W, LI J, *et al.* Intent Contrastive Learning for Sequential Recommendation[C]//Proceedings of the ACM Web Conference 2022. New York: ACM, 2022: 2172–2182. DOI: 10.1145/3485447.3512090.
- [30] LIU C, LI X G, CAI G H, *et al.* Noninvasive Self-attention for Side Information Fusion in Sequential Recommendation[J]. *Proc AAAI Conf Artif Intell*, 2021, 35(5): 4249–4256. DOI: 10.1609/aaai.v35i5.16549.
- [31] XIE Y Q, ZHOU P L, KIM S. Decoupled Side Information Fusion for Sequential Recommendation[C]//Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2022: 1611–1621. DOI: 10.1145/3477495.3531963.
- [32] DAMAK K, KHENISSI S, NASRAOUI O. Debiasing the Cloze Task in Sequential Recommendation with Bidirectional Transformers[C]//Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York: ACM, 2022: 273–282. DOI: 10.1145/3534678.3539430.
- [33] XU C, XU J, CHEN X, *et al.* Dually Enhanced Propensity Score Estimation in Sequential Recommendation[C]//Proceedings of the 31st ACM International Conference on Information & Knowledge Management. New York: ACM, 2022: 2260–2269. DOI: 10.1145/3511808.3557299.
- [34] WANG Z L, ZHANG J S, XU H T, *et al.* Counterfactual Data-augmented Sequential Recommendation[C]//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2021: 347–356. DOI: 10.1145/3404835.3462855.
- [35] TAN Q Y, ZHANG J W, YAO J C, *et al.* Sparse-interest Network for Sequential Recommendation[C]//Proceedings of the 14th ACM International Conference on Web Search and Data Mining. New York: ACM, 2021: 598–606. DOI: 10.1145/3437963.3441811.

- [36] ZHANG X X, CUI P, XU R Z, *et al.* Deep Stable Learning for Out-of-distribution Generalization[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville: IEEE, 2021: 5368–5378. DOI: 10.1109/CVPR46437.2021.00533.
- [37] FAN S H, WANG X, SHI C, *et al.* Generalizing Graph Neural Networks on Out-of-distribution Graphs[J]. *IEEE Trans Pattern Anal Mach Intell*, 2024, **46**(1): 322–337. DOI: 10.1109/TPAMI.2023.3321097.
- [38] LUO Y T, LIU Z C, LIU Q. Deep Stable Representation Learning on Electronic Health Records[C]//2022 IEEE International Conference on Data Mining (ICDM). Orlando: IEEE, 2022: 1077–1082. DOI: 10.1109/ICDM54844.2022.00134.
- [39] LI H Y, WANG X, ZHANG Z W, *et al.* OOD-GNN: Out-of-Distribution Generalized Graph Neural Network [J]. *IEEE Trans Knowl Data Eng*, 2023, **35**(7): 7328–7340. DOI: 10.1109/TKDE.2022.3193725.
- [40] XU R Z, CUI P, SHEN Z Y, *et al.* Why Stable Learning Works? A Theory of Covariate Shift Generalization[EB/OL]. arXiv Preprint: 2111.02355, 2021. <https://doi.org/10.48550/arXiv.2111.02355>.
- [41] COVINGTON P, ADAMS J, SARGIN E. Deep Neural Networks for YouTube Recommendations[C]//Proceedings of the 10th ACM Conference on Recommender Systems. ACM, 2016: 191–198. DOI: 10.1145/2959100.2959190.
- [42] JEAN S, CHO K, MEMISEVIC R, *et al.* On Using very Large Target Vocabulary for Neural Machine Translation [C]//Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Volume 1: Long Papers). Stroudsburg, PA, USA: Association for Computational Linguistics, 2015: 1–10. DOI: 10.3+3115/v1/p15-1001.
- [43] HIDASI B, KARATZOGLOU A, BALTRUNAS L, *et al.* Session-based Recommendations with Recurrent Neural Networks[EB/OL]. arXiv Preprints: 1511.06939, 2015. <https://doi.org/10.48550/arXiv.1511.06939>.