

基于交互行为语义模式增强的ID推荐方法

王远来¹, 白宇^{*1,2}, 廉鹏^{2,3}

¹沈阳航空航天大学计算机学院, 辽宁沈阳, 110136

²多语言协同翻译技术国家地方联合工程实验室, 辽宁沈阳, 110136

³沈阳北软信息职业技术学院, 辽宁沈阳, 110136

wangyuanlai@stu.sau.edu.cn; baiyu@sau.edu.cn; lianp@ge-soft.com

摘要

基于ID的推荐是一种依赖用户或物品的唯一标识符进行推荐的经典推荐方法, 这种方法经常面临用户物品交互数据稀疏、符号ID缺失语义信息等问题。该文针对上述问题, 假设不同领域的用户-物品交互行为之间存在潜在的模式关联, 提出了一种基于交互行为语义模式增强的ID推荐方法。该方法在目标域推荐任务中引入辅助域信息, 基于图神经网络对辅助域和目标域信息进行联合编码表示, 通过引入交互行为语义模式, 将辅助域的用户-物品交互信息以及物品描述信息迁移至目标域, 从而实现目标域ID推荐中的交互行为语义增强。在8个公开数据集上的实验结果表明, 相比目前的SOTA模型, 本文方法表现出更好的推荐效果, 其Recall@20与NDCG@20分别具有3%~30%、1%~40%的提升。

关键词: 推荐系统; 交互行为; 语义模式; 语义增强

Enhanced ID Recommendation Method Utilizing Semantic Patterns of Interactive Behaviors

Yuanlai Wang¹, Yu Bai^{*1,2}, Peng Lian^{2,3}

¹School of Computer Science, Shenyang Aerospace University, Shenyang, Liaoning, 110136

²National & Local Joint Engineering Laboratory of Multi-Language Collaborative Translation Technology, Shenyang, Liaoning, 110136

³Shenyang Northern Software College of Information Technology, Shenyang, Liaoning, 110136

wangyuanlai@stu.sau.edu.cn; baiyu@sau.edu.cn; lianp@ge-soft.com

Abstract

ID-based recommendation is a traditional method in recommendation systems that relies on unique identifiers of users or items for recommendation. However, it often faces challenges such as sparse user-item interaction data and a lack of semantic information in symbolic IDs. This study addresses these issues by suggesting the existence of latent pattern correlations between user-item interaction behaviors across different domains. It proposes an improved ID-based recommendation method that incorporates semantic patterns of interaction behaviors. This approach integrates auxiliary domain information into the target domain recommendation task by utilizing graph neural networks to jointly encode the auxiliary and target domain information. By including semantic patterns of interaction behaviors, it facilitates the transfer of user-item interaction information and item description data from the auxiliary domain to the target domain, thereby enhancing the semantic aspects of interaction behavior in ID-based recommendation for the target domain. Experimental results on eight public datasets have demonstrated that, in comparison to current state-of-the-art (SOTA) models, the

* 通讯作者 Corresponding author.

proposed method achieves superior recommendation performance, with enhancements in Recall@20 ranging from 3% to 30% and NDCG@20 ranging from 1% to 40%.

Keywords: Recommended system , Interactive behavior , Semantic pattern , Semantic enhancement

1 引言

推荐系统(Wang et al., 2021)因其能向用户提供个性化推荐服务而具有广泛的应用场景(Yu et al., 2022; Huang et al., 2021)。对推荐系统的研究一直是工业界和学术界关注的焦点之一。

基于ID的推荐是一种简单直接的推荐系统实现方法,其主要利用用户和物品的交互信息实现个性化推荐。通常,推荐系统将用户与物品视为基本处理单元,并为其分配唯一的离散标识(ID),用户和物品的交互信息通常被表示为用户-ID与Item-ID的对应关系集合。基于ID的推荐系统通过对这些对应关系的模式学习来获取对用户和物品的有效表示(Fan et al., 2023),进而实现从离散的ID中捕捉用户对物品的偏好。然而,这种基于ID的推荐方法往往面临用户-物品交互数据稀疏、符号ID不含有语义信息等问题。

STAR(Sheng et al., 2021)、PeterRec(Yuan et al., 2022)、ALCDR(Zhao et al., 2023)等工作基于协同过滤思想,利用不同推荐平台之间共享的用户或物品信息,实现在不同领域间传输用户或物品级偏好的目的,这类方法可用于解决跨域推荐问题或冷启动推荐问题。但是,这些方法效果严重依赖不同领域间用户或物品的重叠,而在实际场景中,这种重叠假设几乎不成立(Yuan et al., 2023),此外,用户和物品的ID仅作为一种索引符号,因而其本身无法为用户和物品的表示提供有价值的语义信息(Fan et al., 2023)。

对交互行为的研究表明,个体倾向于与其所属的群体相关联,群体的所有成员通常具有相似的购买行为并且彼此之间具有显著的影响力。例如,个体的职业背景会影响其购买行为(Naim, 2023),人们倾向于购买与其职业和社会角色相符的产品和服务。这里,职业作为一种潜在驱动因素,使群体用户表现出特定的购买行为模式。同时,潜在的模式关联能够从多个角度捕捉用户偏好,进而提高模型的表现(Zhang et al., 2024)。因此,我们假设不同域用户-物品交互行为之间存在潜在的模式关联,如图1所示。即,存在一种将不同域的用户连接的潜在因素,在该因素驱动下,不同域间的部分用户产生出相近的用户-物品交互行为,我们把这些相近交互行为之间的公共特征称为交互行为语义模式。




图 1. 交互行为语义模式表达潜在联系的示意

基于上述假设,本文提出了一种基于交互行为语义模式增强的ID推荐方法。该方法在目标域推荐任务中引入辅助域信息,基于图神经网络对辅助域和目标域信息进行联合编码表示,通过引入交互行为语义模式,将辅助域的用户-物品交互信息以及物品描述信息迁移至目标域,从而实现目标域ID推荐中的交互行为语义增强。本文的主要贡献如下:

(1) 提出交互行为语义模式的假设,基于此构建基于交互行为语义模式的推荐方法,该方法能够在不依赖领域间用户或物品重叠的情况下,有效提升推荐效果。

(2) 提出了基于交互行为语义模式增强的目标域的用户和物品表示模型PEIDR,通过图神经网络和预训练语言模型实现辅助域关联模式信息到目标域的迁移,从而增强目标域的用户和物品的语义表达。

(3) 在8个公开数据集上进行了实验, 结果表明, 相比于当前的SOTA模型, 本文提出的方法均获得了更好的表现, 其Recall@20与NDCG@20分别具有3% ~ 30%、1% ~ 40%的提升, 说明了本文提出假设的合理性及方法的有效性。

2 相关研究

基于单一领域数据实现的推荐系统长期面临数据稀疏和冷启动两大挑战, 这促进了跨域推荐的出现和发展。跨域推荐的核心思想是利用从其他领域(辅助域)收集的信息来缓解目标领域中的数据稀疏和冷启动问题(Zang et al., 2022)。与传统推荐系统相比, 跨领域推荐更为复杂。首先, 考虑到两个域的用户和物品之间的关系, 跨域推荐存在用用户重叠或非重叠等不同的推荐情况(Khan et al., 2017)。其次, 跨领域推荐的推荐任务多种多样。例如, 推荐用户和物品可能在同一领域, 也可能在不同领域。最后, 传统的推荐系统只需关注如何从历史交互记录中建立用户兴趣模型, 对于跨领域推荐来说, 除了在一个领域内对用户兴趣建模外, 还需要考虑如何在不同领域之间传递知识。Man(2017)等人提出的EMCDR是一种经典的基于映射的方法, 它通过学习映射函数在不同域之间转移重叠用户的偏好。Li(2020)等人提出的DDTCDR引入了一种潜在的正交映射来捕捉多个领域中的用户偏好, 同时保留不同潜在空间中用户之间的关系。Xie(2022)等人提出的CCDR在不同领域之间对用户和物品属性进行对比学习, 以实现多样化的知识转移。然而, 这些仅基于ID关联记录的方法忽略了物品描述中的语义信息在推荐中的重要性。

SGL(Wu et al., 2021)将节点丢失(Node Dropout)、边缘丢失(Edge Dropout)和随机游走(Random Walk)应用于增强用户-物品二分图。它使用相同类型的增强算子生成两个增强图, 并使用共享图LightGCN 编码器 f_{θ} (He et al., 2020)学习节点嵌入。Yu(2023)等人将对比学习引入推荐任务, 利用用户-物品交互行为数据构建二分图, 提出XSimGCL模型并证明了对比学习对图推荐模型的有益影响, XSimGCL模型通过优化对比损失InfoNCE获得比SGL(Wu et al., 2021)模型更为合理的用户与物品表征。本文的方法在XSimGCL模型的基础上再次优化用户与物品的特征表示, 将辅助域中物品的语义信息融入目标域以获得带有语义信息的用户与物品的表示。

3 模型实现

3.1 问题定义

本文使用的符号及含义如表1所示。

| 符号名 | 意义 |
|-----------------|----------------------------|
| U_i^t | 目标域中用户 i 的特征表示 |
| I_j^t | 目标域中物品 j 的特征表示 |
| U^t | 目标域中用户特征表示的集合 |
| I^t | 目标域中物品特征表示的集合 |
| $U_i^{t\prime}$ | 目标域中用户 i 融入语义的特征表示 |
| $I_j^{t\prime}$ | 目标域中物品 j 融入语义的特征表示 |
| T_i | $item_i^a$ 的文本描述 |
| S_i | 辅助域中物品文本描述 i 的特征表示 |
| U_i^a | 辅助域中用户 i 的特征表示 |
| I_j^a | 辅助域中物品 j 的特征表示 |
| U^a | 辅助域中用户特征表示的集合 |
| I^a | 辅助域中物品特征表示的集合 |
| \bar{U}_j^a | 与 $user_j^a$ 存在交互的物品的平均化表示 |
| \bar{U}^a | \bar{U}_j^a 的集合 |

表 1. 符号及其意义

在基于交互行为语义模式增强的ID推荐方法中，有来自于目标域和辅助域的两组用户集合，分别表示为 $User^t = \{user_1^t, user_2^t, user_3^t \dots user_m^t\}$ 和 $User^a = \{user_1^a, user_2^a, user_3^a \dots user_n^a\}$ ，其中 m, n 分别为目标域和辅助域中用户的个数；另有来自于目标域和辅助域的两组物品集合，分别表示为 $Item^t = \{item_1^t, item_2^t, item_3^t \dots item_p^t\}$ 和 $Item^a = \{item_1^a, item_2^a, item_3^a \dots item_q^a\}$ ，其中 p, q 分别为目标域和辅助域中物品的个数。User^t与User^a，Item^t与Item^a中均无重叠项，即， $User^a \cap User^t = \emptyset$ ； $Item^a \cap Item^t = \emptyset$ 。辅助域和目标域中的数据分别构成两个二分图，并以三元组(User-ID, Item-ID, InteractionFlag)的形式表示，其中，InteractionFlag={0,1}表示用户是否与物品存在交互。基于交互行为语义模式增强的ID推荐的目标是利用辅助域信息指导推荐模型在目标域上获得更为准确的物品推荐结果，该问题可形式化表示如下。

$$\max \sum_i^m \sum_j^p (2c_{ij} - 1)x_{ij}. \quad (1)$$

其中， $c_{ij} = \{0, 1\}$ 。 $c_{ij} = 0$ 表示 $user_i^t$ 与 $item_j^t$ 之间没有交互， $c_{ij} = 1$ 表示 $user_i^t$ 与 $item_j^t$ 之间存在交互； $x_{ij} = \{0, 1\}$ 。 $x_{ij} = 0$ 表示模型预测 $user_i^t$ 与 $item_j^t$ 之间没有交互， $x_{ij} = 1$ 表示模型预测 $user_i^t$ 与 $item_j^t$ 之间存在交互。

3.2 模型概述

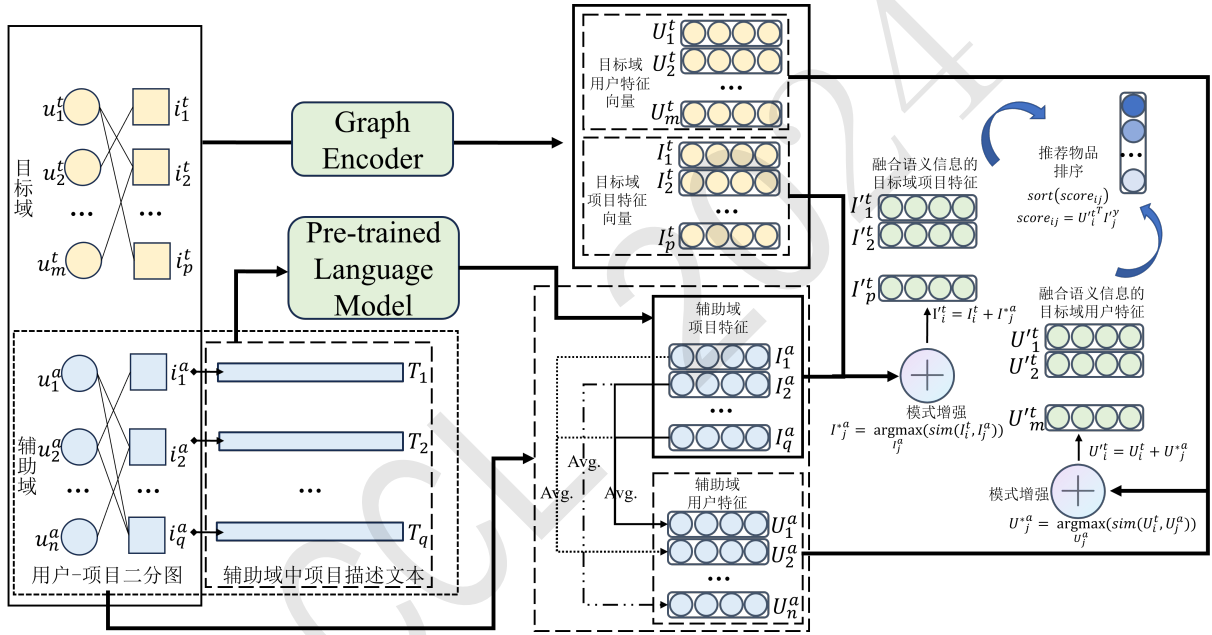


图 2. 模型结构图

本文设计了基于交互行为语义模式增强的目标域用户和物品表示模型PEIDR。为了引入语义信息，使用三元组(Item-ID, Title, Describe)间接建立辅助域中的物品描述信息(Describe)与用户的交互关系。PEIDR模型通过图神经网络和预训练语言模型实现辅助域关联模式信息到目标域的迁移，从而增强目标域的用户和物品的语义表达。另外，为了进一步提升推荐的质量和推荐的准确性，通过优化推荐损失的方式增强了用户和物品的特征表示。基于交互行为语义模式增强过程如算法1所示。

3.2.1 交互行为语义模式增强

PEIDR模型的结构图如图2所示。通过图编码器 $XSimGCL$ (Yu et al., 2023)对目标域和辅助域的用户-物品二分图进行联合编码，得到目标域和辅助域中的用户与物品的嵌入向量。为了获取辅助域物品描述文本的语义信息，我们使用预训练语言模型BGE(Zhang et al., 2023)对辅助域中每个物品的文本描述 $T_j \in T, j \in C_N[1, q]$ 进行编码。

$$S_j = Encoder(T_j). \quad (2)$$

S_j 被用来更新由图编码器产生的辅助域中用户与物品的特征。在辅助域中，为了获取符合用户偏好的语义特征，使用与该用户存在交互的所有物品特征平均化对其进行更新。其中， $\sum_j c_{ij}$ 表示 $user_i^a$ 与辅助域中物品交互的数量， $i \in C_{\mathbb{N}}[1, n]$ ， $j \in C_{\mathbb{N}}[1, q]$ 。

$$U_i^a = \frac{\sum_j c_{ij} \cdot S_j}{\sum_j c_{ij}}, \quad c_{ij} = \{0, 1\}. \quad (3)$$

目标域用户 $user_i^t$ 更新后的表示向量 U_i^{tt} 由其更新前的表示向量 U_i^t 和与之距离最近的辅助域用户 $user_j^a$ 的表示向量 U_j^{*a} 相加得到。获取融入语义信息的用户特征表示过程可形式化描述如下：

$$U_i^{tt} = U_i^t + U_j^{*a}. \quad (4)$$

$$U_j^{*a} = \operatorname{argmax}_{U_j^a} (\operatorname{sim}(U_i^t, U_j^a)). \quad (5)$$

其中， $U_i^t \in U^t$ ， $U_j^a \in U^a$ ， $i \in C_{\mathbb{N}}[1, m]$ ， $j \in C_{\mathbb{N}}[1, n]$ 。

目标域物品 $item_i^t$ 更新后的表示向量 I_i^{tt} 由其更新前的表示向量 I_i^t 和与之距离最近的辅助域物品 $item_j^a$ 的表示向量 I_j^{*a} 相加得到。获取融入语义信息的物品特征表示过程可形式化描述如下：

$$I_i^{tt} = I_i^t + I_j^{*a}. \quad (6)$$

$$I_j^{*a} = \operatorname{argmax}_{I_j^a} (\operatorname{sim}(I_i^t, I_j^a)). \quad (7)$$

$$I_j^a = \operatorname{Encoder}(T_j). \quad (8)$$

其中， $I_i^t \in I^t$ ， $I_j^a \in I^a$ ， $i \in C_{\mathbb{N}}[1, p]$ ， $j \in C_{\mathbb{N}}[1, q]$ 。

基于用户与物品的特征向量点积计算排序结果为用户推荐TopK个物品， $K=20$ 。

$$\operatorname{score}_{ij} = U_i^{tt\top} I_j^{tt}. \quad (9)$$

3.2.2 优化推荐损失

为了提高推荐系统整体性能，本文采用由超参数 λ 调节的推荐损失与对比损失联合的方式(Yu et al., 2023)进行模型优化。

$$L = L_{rec} + \lambda L_{cl}. \quad (10)$$

假设 \mathcal{B} 为当前批次，则 u 和 i 分别表示 \mathcal{B} 中的用户与物品序号。对比损失最小化使得图对比学习模型能够从ID的交互信息中学习更均匀的物品表示。

$$L_{cl} = \sum_{u \in \mathcal{B}} -\log \left(\frac{\exp(z_u'^{\top} z_u^{l*} / \tau)}{\sum_{i \in \mathcal{B}} \exp(z_u'^{\top} z_i^{l*} / \tau)} \right). \quad (11)$$

其中， z_u' 和 z_u^{l*} 是来自不同的层嵌入的用户特征， l^* 表示与最终层对比的层序数， τ 是温度系数，控制对难负样本的惩罚强度。

考虑到将语义信息融入目标域中的用户和物品表示过程，推荐损失定义如下：

$$L_{rec} = - \sum_{(u,i) \in \mathcal{B}} \log \left(\sigma \left(e_{u_s}^{\top} e_{i_s} - e_{u_s}^{\top} e_{j_s} \right) \right). \quad (12)$$

其中， e_{u_s} 表示融合了语义信息的用户表示， e_{i_s} 表示与用户 u 存在交互的且融合了语义信息的物品表示， e_{j_s} 是随机采样的与用户不存在交互且融入语义信息的物品表示， σ 是sigmoid函数。

算法 1 基于交互行为语义模式增强算法**Input:** The User-Item bipartite graphs from the target domain and auxiliary domains.**Output:** Optimized Graph Encoder

```

1:  $S \leftarrow Encoder(T)$ 
2: for each  $U_j^a$  in  $U^a$  do
3:   //  $S_1, S_2, \dots, S_k$  为与  $user_j^a$  存在交互的物品表征,  $k$  为物品数量
4:    $\bar{U}_j^a \leftarrow mean(S_1, S_2, \dots, S_k)$ 
5:    $\bar{U}^a.add(\bar{U}_j^a)$ 
6: end for
7: for  $epoch$  in  $range(max\_epoch)$  do
8:    $U^t, I^t \leftarrow model\_graph\_encoder$ 
9:   for each  $U_i^t$  in  $U^t$  do
10:    for each  $TempU_j^a$  in  $\bar{U}^a$  do //  $TempU_j^a$  为临时变量
11:      $U_j^{*a} \leftarrow \underset{U_j^a}{argmax}(sim(U_i^t, TempU_j^a))$ 
12:    end for
13:     $U_i^{tt} \leftarrow U_i^t + U_j^{*a}$ 
14:  end for
15:  for each  $I_i^t$  in  $I^t$  do
16:   for each  $I_j^a$  in  $I^a$  do
17:    // 预训练语言模型对  $item_j^a$  的表示替换 Graph Encoder 对  $item_j^a$  的表示
18:     $I_j^a \leftarrow Encoder(T_j)$ 
19:     $I_j^{*a} \leftarrow \underset{I_j^a}{argmax}(sim(I_i^t, I_j^a))$ 
20:   end for
21:    $I_i^{tt} \leftarrow I_i^t + I_j^{*a}$ 
22:  end for
23:   $L \leftarrow L_{rec} + \lambda L_{cl}$ 
24:   $L.backward$ 
25: end for
26: return  $U_i^{tt}, I_j^{tt}$ 
27:  $score_{ij} \leftarrow U_i^{tt\top} I_j^{tt}$ 
28:  $sort(score_{ij})$ 

```

4 实验

4.1 数据集

为了获得可靠且令人信服的结果，本文在8个公共数据集上进行了交叉实验评估。其中，Yelp2018⁰(He et al., 2020)、Amazon-kindle¹(He and McAuley, 2016)、Alibaba-iFashion²(Wu et al., 2021)、Amazon-Electronic³(Ni et al., 2019)、Book Crossing Dataset⁴(Hu et al., 2023)等是仅包含用户-物品ID交互信息的数据集，这里仅作为目标域数据集使用；MovieLens10M⁵(Lee et al., 2022)、MovieLens20M⁴(Yi et al., 2023)、MovieLens25M⁴(Ji et al., 2023)和Citeulike-a⁶等是包含物品描述信息的数据集，这里逐一作为实验的辅助域数据集使用。目标域与辅助域中既没有重叠的用户也不存在重叠的物品。

⁰<https://github.com/kuandeng/LightGCN/tree/master/Data/yelp2018>¹<https://github.com/Coder-Yu/SELFRec/tree/main/dataset/amazon-kindle>²<https://github.com/Coder-Yu/SELFRec/tree/main/dataset/iFashion>³<https://cseweb.ucsd.edu/~jmcauley/datasets/amazon/links.html>⁴<https://grouplens.org/datasets/book-crossing/>⁵<https://grouplens.org/datasets/movieLens/>⁶<https://github.com/js05212/citeulike-a>

| Dataset | User | Item | Interactions | Describe | Density |
|-----------------------|--------|--------|--------------|----------|---------|
| Yelp2018 | 31668 | 38048 | 1561406 | - | 1.3e-3 |
| Amazon-kindle | 138333 | 98572 | 1909965 | - | 1.4e-4 |
| Alibaba-iFashion | 300000 | 81614 | 1607813 | - | 7.0e-5 |
| Amazon-Electronics | 719376 | 159364 | 5460975 | - | 5.0e-6 |
| Book Crossing Dataset | 61844 | 142000 | 351646 | - | 4.0e-5 |
| MovieLens10M | 69878 | 10677 | 10000054 | ✓ | 1.3e-2 |
| MovieLens20M | 7120 | 14026 | 1048575 | ✓ | 1.0e-2 |
| MovieLens25M | 7045 | 22240 | 1048575 | ✓ | 7.0e-3 |
| Citeulike-a | 5551 | 16980 | 204986 | ✓ | 2.2e-3 |

表 2. 实验数据的详细信息

各数据集中的数据分别情况如表2所示。本文将各目标域数据集按7:1:2的比例分为三部分（训练集、验证集和测试集）进行独立验证实验，使用基于相关性的指标Recall@20和基于排名的指标NDCG@20对推荐结果进行评价。

4.2 超参数设置

本研究中的实验采用自监督推荐的框架SELFRec⁷实现所有的模型和基线。选用预训练语言模型BGE(Zhang et al., 2023)作为语义提取器。在模型中设置向量维度为768维，并使用Adam优化器来最小化损失函数。学习率设置为 10^{-4} ， L_2 正则化系数设置为 10^{-4} ，批次大小设置为2048，温度系数 τ 设置为0.2，超参数 λ 设置为0.2， l^* 设置为1。在训练过程中，使用公式(10)损失函数来训练模型，并采用批量梯度下降算法进行优化。

4.3 对比基线

(1) LightGCN(He et al., 2020): LightGCN 通过用户-物品交互图上线性传播用户和物品嵌入来学习用户和物品嵌入，并使用所有层学习到的嵌入的加权和作为最终嵌入。

(2) SGL(Wu et al., 2021): 自监督图学习范式。SGL-ND(Node Dropout)、SGL-ED(Edge Dropout)和SGL-RW(Random Walk)为图结构上三中不同的操作，根据不同的视图减少噪声的影响，达到图增强的目的。

(3) SGL-WA(Yu et al., 2022): 改进SGL变体，提出并非所有图增强都会产生积极影响，某些图增强（例如Node Dropout）可能会通过删除关键节点（例如中心）及其相关边来扭曲原始图，并证明在图对比学习中，对比损失的选择比图增强更有效果。

(3) SimGCL(Yu et al., 2022): 消除了无效的图形增强，而是通过向学习的表示添加均匀噪声来实现更有效表示。经验结果表明，这种基于噪声的增强可以获得更均匀的表示分布。

(4) XSimGCL(Yu et al., 2023): 优化SimGCL，是对比任务和推荐任务共享通道，简化计算过程。

4.4 实验结果

本文研究方法与基线方法进行了比较，实验结果汇总在表3中，每个指标的最佳分数用粗体表示，次优指标用下划线表示。实验结果表明，本文提出的方法在不同的数据集中都表现出了有效性。

4.5 结果分析

4.5.1 交互行为语义模式的可转移性

通过分析8个数据集中涉及的推荐物品的领域，我们研究了潜在行为模式的领域可转移性。

如图3所示，当我们使用Citeulike-a作为辅助域信息观察目标域中的推荐结果时，我们发现不同目标域之间的推荐效果存在差异。数据集Amazon-kindle、Amazon-Electronic和Book Crossing Dataset与数据集Yelp2018、Alibaba-iFashion、MovieLens10M、MovieLens20M和Movie-

⁷<https://github.com/Coder-Yu/SELFRec>

| Dataset | Evaluation | Method | | | | | | | |
|-----------------------|------------|----------|--------|--------|---------------|--------|--------|---------------|---------------|
| | | LightGCN | SGL-ND | SGL-ED | SGL-RW | SGL-WA | SimGCL | XSimGCL | PEIDR(Ours) |
| Yelp2018 | Recall@20 | 0.0622 | 0.0658 | 0.0668 | 0.0644 | 0.0653 | 0.0719 | <u>0.0722</u> | 0.0744 |
| | NDCG@20 | 0.0504 | 0.0538 | 0.0549 | 0.0530 | 0.0544 | 0.0601 | <u>0.0604</u> | 0.0613 |
| Amazon-Kindle | Recall@20 | 0.2033 | 0.2020 | 0.2084 | 0.2088 | 0.2068 | 0.2071 | <u>0.2114</u> | 0.2756 |
| | NDCG@20 | 0.1284 | 0.1307 | 0.1341 | 0.1345 | 0.1330 | 0.1341 | <u>0.1382</u> | 0.1948 |
| Alibaba-iFashion | Recall@20 | 0.1053 | 0.0993 | 0.1062 | 0.1053 | 0.1028 | 0.1119 | <u>0.1143</u> | 0.1295 |
| | NDCG@20 | 0.0505 | 0.0484 | 0.0514 | 0.0512 | 0.0501 | 0.0548 | <u>0.0559</u> | 0.0637 |
| Amazon-Electronics | Recall@20 | 0.0545 | 0.0665 | 0.0688 | 0.0692 | 0.0681 | 0.0698 | <u>0.0704</u> | 0.0943 |
| | NDCG@20 | 0.0352 | 0.0465 | 0.0496 | 0.0497 | 0.0489 | 0.0493 | <u>0.0521</u> | 0.0725 |
| MovieLens10M | Recall@20 | 0.2747 | 0.2642 | 0.2735 | 0.2726 | 0.2741 | 0.2854 | <u>0.3002</u> | 0.3080 |
| | NDCG@20 | 0.3345 | 0.3208 | 0.3302 | 0.3295 | 0.3309 | 0.3373 | <u>0.3591</u> | 0.3720 |
| MovieLens20M | Recall@20 | 0.2305 | 0.2368 | 0.2446 | 0.2438 | 0.2456 | 0.2381 | <u>0.2615</u> | 0.2713 |
| | NDCG@20 | 0.2938 | 0.3032 | 0.3116 | 0.3135 | 0.3119 | 0.2909 | <u>0.3262</u> | 0.3407 |
| MovieLens25M | Recall@20 | 0.2256 | 0.2360 | 0.2423 | 0.2425 | 0.2419 | 0.2398 | <u>0.2606</u> | 0.2711 |
| | NDCG@20 | 0.2894 | 0.2995 | 0.3094 | 0.3076 | 0.3076 | 0.2937 | <u>0.3257</u> | 0.3386 |
| Book Crossing Dataset | Recall@20 | 0.0426 | 0.0454 | 0.0481 | <u>0.0483</u> | 0.0452 | 0.0431 | 0.0444 | 0.0603 |
| | NDCG@20 | 0.0235 | 0.0263 | 0.0274 | <u>0.0278</u> | 0.0261 | 0.0242 | 0.0249 | 0.0361 |

表 3. PEIDR和基线在8个数据集上的比较结果

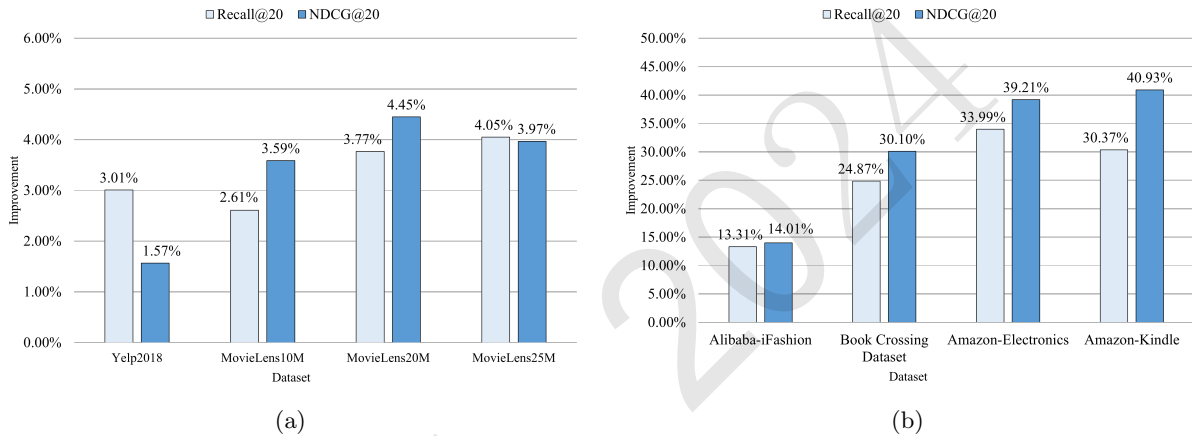


图 3. PEIDR与最新SOTA模型的提升对比

与MovieLens25M相比，前者在推荐效果上的提升更加明显，这说明辅助域中的推荐项属性与目标域中的推荐项属性越接近，辅助域信息的传递增强效果越好。

4.5.2 交互行为语义模式的有效性

为了证明潜在行为模式增强的有效性，进行了有无行为语义模式增强的消融实验，消融实验的超参数设置与对比试验中的PEIDR方法相同。如表4所示的实验结果表明，引入行为语义模式增强能够有效地提升模型的推荐结果。

| 数据集 | Recall@20 | | | NDCG@20 | | |
|-----------------------|-------------|-----------|-------------|-------------|-----------|-------------|
| | PEIDR(Ours) | 无行为语义模式增强 | Improvement | PEIDR(Ours) | 无行为语义模式增强 | Improvement |
| Yelp2018 | 0.0744 | 0.0729 | 2.04% | 0.0613 | 0.0602 | -1.88% |
| Amazon-Kindle | 0.2756 | 0.2330 | 18.28% | 0.1948 | 0.1500 | -29.87% |
| Alibaba-iFashion | 0.1295 | 0.1172 | 10.50% | 0.0637 | 0.0568 | -12.16% |
| Amazon-Electronics | 0.0943 | 0.0840 | 12.34% | 0.0725 | 0.0635 | -14.24% |
| MovieLens10M | 0.3080 | 0.2914 | 5.72% | 0.3720 | 0.3557 | -4.59% |
| MovieLens20M | 0.2713 | 0.2631 | 3.13% | 0.3407 | 0.3359 | -1.44% |
| MovieLens25M | 0.2711 | 0.2623 | 3.38% | 0.3386 | 0.3333 | -1.57% |
| Book Crossing Dataset | 0.0603 | 0.0515 | 16.94% | 0.0361 | 0.0319 | -13.12% |

表 4. 消融实验结果

4.5.3 交互行为语义模式的鲁棒性

为了验证交互行为语义模式的鲁棒性，我们分别使用带文本描述信息的MovieLens10M、MovieLens20M和MovieLens25M作为辅助域数据集进行交叉验证。为了避免样本数量差异对实验结果的影响，我们随机选取与Citeulike-a相同数量的用户-物品交互记录作为辅助域数据。实验结果如表5至表7所示。每个指标的最佳分数用粗体表示，次优指标用下划线表示，表中最后一列表示该数据集的最佳结果相比次优结果的提升率。实验结果进一步表明，使用不同的辅助域数据在本文PEIDR模型框架下均产生了不同程度推荐效果的提升，表明本文提出的交互行为语义模式具有鲁棒性。

| Dataset | Evaluation | Method | | | | | | | | Improvement |
|-----------------------|------------|----------|--------|--------|---------------|--------|--------|---------------|---------------|-------------|
| | | LightGCN | SGL-ND | SGL-ED | SGL-RW | SGL-WA | SimGCL | XSimGCL | PEIDR(Ours) | |
| Yelp2018 | Recall@20 | 0.0622 | 0.0658 | 0.0668 | 0.0644 | 0.0653 | 0.0719 | <u>0.0722</u> | 0.0742 | 2.80% |
| | NDCG@20 | 0.0504 | 0.0538 | 0.0549 | 0.0530 | 0.0544 | 0.0601 | <u>0.0604</u> | 0.0613 | 1.49% |
| Amazon-Kindle | Recall@20 | 0.2033 | 0.2020 | 0.2084 | 0.2088 | 0.2068 | 0.2071 | <u>0.2114</u> | 0.2740 | 29.62% |
| | NDCG@20 | 0.1284 | 0.1307 | 0.1341 | 0.1345 | 0.1330 | 0.1341 | <u>0.1382</u> | 0.1938 | 40.23% |
| Alibaba-iFashion | Recall@20 | 0.1053 | 0.0993 | 0.1062 | 0.1053 | 0.1028 | 0.1119 | <u>0.1143</u> | 0.1284 | 12.30% |
| | NDCG@20 | 0.0505 | 0.0484 | 0.0514 | 0.0512 | 0.0501 | 0.0548 | <u>0.0559</u> | 0.0631 | 12.81% |
| Amazon-Electronics | Recall@20 | 0.0545 | 0.0665 | 0.0688 | 0.0692 | 0.0681 | 0.0698 | <u>0.0704</u> | 0.0935 | 32.84% |
| | NDCG@20 | 0.0352 | 0.0465 | 0.0496 | 0.0497 | 0.0489 | 0.0493 | <u>0.0521</u> | 0.0718 | 37.85% |
| citeulike-a | Recall@20 | 0.2361 | 0.2511 | 0.2620 | <u>0.2628</u> | 0.2591 | 0.2413 | 0.2590 | 0.2806 | 6.78% |
| | NDCG@20 | 0.1929 | 0.2064 | 0.2148 | <u>0.2158</u> | 0.2128 | 0.2045 | 0.2150 | 0.2334 | 8.13% |
| Book Crossing Dataset | Recall@20 | 0.0426 | 0.0454 | 0.0481 | <u>0.0483</u> | 0.0452 | 0.0431 | 0.0444 | 0.0546 | 13.12% |
| | NDCG@20 | 0.0235 | 0.0263 | 0.0274 | <u>0.0278</u> | 0.0261 | 0.0242 | 0.0249 | 0.0325 | 17.10% |

表 5. 使用数据集MovieLens10M作为辅助域的增强结果

| Dataset | Evaluation | Method | | | | | | | | Improvement |
|-----------------------|------------|----------|--------|--------|---------------|--------|--------|---------------|---------------|-------------|
| | | LightGCN | SGL-ND | SGL-ED | SGL-RW | SGL-WA | SimGCL | XSimGCL | PEIDR(Ours) | |
| Yelp2018 | Recall@20 | 0.0622 | 0.0658 | 0.0668 | 0.0644 | 0.0653 | 0.0719 | <u>0.0722</u> | 0.0742 | 2.77% |
| | NDCG@20 | 0.0504 | 0.0538 | 0.0549 | 0.0530 | 0.0544 | 0.0601 | <u>0.0604</u> | 0.0614 | 1.59% |
| Amazon-Kindle | Recall@20 | 0.2033 | 0.2020 | 0.2084 | 0.2088 | 0.2068 | 0.2071 | <u>0.2114</u> | 0.2752 | 30.19% |
| | NDCG@20 | 0.1284 | 0.1307 | 0.1341 | 0.1345 | 0.1330 | 0.1341 | <u>0.1382</u> | 0.1951 | 41.14% |
| Alibaba-iFashion | Recall@20 | 0.1053 | 0.0993 | 0.1062 | 0.1053 | 0.1028 | 0.1119 | <u>0.1143</u> | 0.1284 | 12.33% |
| | NDCG@20 | 0.0505 | 0.0484 | 0.0514 | 0.0512 | 0.0501 | 0.0548 | <u>0.0559</u> | 0.0631 | 12.84% |
| Amazon-Electronics | Recall@20 | 0.0545 | 0.0665 | 0.0688 | 0.0692 | 0.0681 | 0.0698 | <u>0.0704</u> | 0.0936 | 32.88% |
| | NDCG@20 | 0.0352 | 0.0465 | 0.0496 | 0.0497 | 0.0489 | 0.0493 | <u>0.0521</u> | 0.0719 | 37.97% |
| citeulike-a | Recall@20 | 0.2361 | 0.2511 | 0.2620 | <u>0.2628</u> | 0.2591 | 0.2413 | 0.2590 | 0.2822 | 7.39% |
| | NDCG@20 | 0.1929 | 0.2064 | 0.2148 | <u>0.2158</u> | 0.2128 | 0.2045 | 0.2150 | 0.2343 | 8.57% |
| Book Crossing Dataset | Recall@20 | 0.0426 | 0.0454 | 0.0481 | <u>0.0483</u> | 0.0452 | 0.0431 | 0.0444 | 0.0604 | 25.16% |
| | NDCG@20 | 0.0235 | 0.0263 | 0.0274 | <u>0.0278</u> | 0.0261 | 0.0242 | 0.0249 | 0.0350 | 25.89% |

表 6. 使用数据集MovieLens20M作为辅助域的增强结果

| Dataset | Evaluation | Method | | | | | | | | Improvement |
|-----------------------|------------|----------|--------|--------|---------------|--------|--------|---------------|---------------|-------------|
| | | LightGCN | SGL-ND | SGL-ED | SGL-RW | SGL-WA | SimGCL | XSimGCL | PEIDR(Ours) | |
| Yelp2018 | Recall@20 | 0.0622 | 0.0658 | 0.0668 | 0.0644 | 0.0653 | 0.0719 | <u>0.0722</u> | 0.0742 | 2.80% |
| | NDCG@20 | 0.0504 | 0.0538 | 0.0549 | 0.0530 | 0.0544 | 0.0601 | <u>0.0604</u> | 0.0612 | 1.32% |
| Amazon-Kindle | Recall@20 | 0.2033 | 0.2020 | 0.2084 | 0.2088 | 0.2068 | 0.2071 | <u>0.2114</u> | 0.2757 | 30.41% |
| | NDCG@20 | 0.1284 | 0.1307 | 0.1341 | 0.1345 | 0.1330 | 0.1341 | <u>0.1382</u> | 0.1952 | 41.24% |
| Alibaba-iFashion | Recall@20 | 0.1053 | 0.0993 | 0.1062 | 0.1053 | 0.1028 | 0.1119 | <u>0.1143</u> | 0.1284 | 12.31% |
| | NDCG@20 | 0.0505 | 0.0484 | 0.0514 | 0.0512 | 0.0501 | 0.0548 | <u>0.0559</u> | 0.0632 | 12.97% |
| Amazon-Electronics | Recall@20 | 0.0545 | 0.0665 | 0.0688 | 0.0692 | 0.0681 | 0.0698 | <u>0.0704</u> | 0.0934 | 32.67% |
| | NDCG@20 | 0.0352 | 0.0465 | 0.0496 | 0.0497 | 0.0489 | 0.0493 | <u>0.0521</u> | 0.0718 | 37.87% |
| citeulike-a | Recall@20 | 0.2361 | 0.2511 | 0.2620 | <u>0.2628</u> | 0.2591 | 0.2413 | 0.2590 | 0.2861 | 8.85% |
| | NDCG@20 | 0.1929 | 0.2064 | 0.2148 | <u>0.2158</u> | 0.2128 | 0.2045 | 0.2150 | 0.2391 | 10.81% |
| Book Crossing Dataset | Recall@20 | 0.0426 | 0.0454 | 0.0481 | <u>0.0483</u> | 0.0452 | 0.0431 | 0.0444 | 0.0577 | 19.64% |
| | NDCG@20 | 0.0235 | 0.0263 | 0.0274 | <u>0.0278</u> | 0.0261 | 0.0242 | 0.0249 | 0.0343 | 23.62% |

表 7. 使用数据集MovieLens25M作为辅助域的增强结果

5 结论

本文针对基于ID的推荐方法经常面临用户-物品交互数据稀疏、符号ID缺失语义信息等问题，提出了不同领域用户-物品交互行为之间存在潜在的模式关联的假设，并基于此提出了一种基于交互行为语义模式增强的ID推荐方法。实验结果表明，相比当前SOTA模型，该方法能够在无跨域用户和物品重叠的情况下实现语义信息迁移，并表现出更好的推荐效果，说明了本文提出假设的合理性及方法的有效性；在多个领域ID推荐任务上的实验表明，相近领域之间的交互行为模式具有更好的可迁移性，辅助域与目标域越接近，引入辅助域信息对目标域ID推荐结果提升越明显。

致谢

本文受到国家自然科学基金(U1908216)的资助。

参考文献

- Wenqi Fan, Zihuai Zhao, Jiatong Li, Yunqing Liu, Xiaowei Mei, Yiqi Wang, Jiliang Tang, and Qing Li. 2023. Recommender systems in the era of large language models (llms). arxiv 2023. *arXiv preprint arXiv:2307.02046*.
- Ruining He and Julian McAuley. 2016. Ups and downs: Modeling the visual evolution of fashion trends with one-class collaborative filtering. In *proceedings of the 25th international conference on world wide web*, pages 507–517.
- Xiangnan He, Kuan Deng, Xiang Wang, Yan Li, Yongdong Zhang, and Meng Wang. 2020. Lightgcn: Simplifying and powering graph convolution network for recommendation. In *Proceedings of the 43rd International ACM SIGIR conference on research and development in Information Retrieval*, pages 639–648.
- Zheng Hu, Shi-Min Cai, Jun Wang, and Tao Zhou. 2023. Collaborative recommendation model based on multi-modal multi-view attention network: Movie and literature cases. *Applied Soft Computing*, page 110518.
- Chao Huang, Huance Xu, Yong Xu, Peng Dai, Lianghao Xia, Mengyin Lu, Liefeng Bo, Hao Xing, Xiaoping Lai, and Yanfang Ye. 2021. Knowledge-aware coupled graph neural network for social recommendation. In *Proceedings of the AAAI conference on artificial intelligence*, volume 35, pages 4115–4122.
- Yitong Ji, Aixin Sun, Jie Zhang, and Chenliang Li. 2023. A critical study on data leakage in recommender system offline evaluation. *ACM Transactions on Information Systems*, 41(3):1–27.
- Muhammad Murad Khan, Roliana Ibrahim, and Imran Ghani. 2017. Cross domain recommender systems: a systematic literature review. *ACM Computing Surveys (CSUR)*, 50(3):1–34.
- Jae-woong Lee, Seongmin Park, Joonseok Lee, and Jongwuk Lee. 2022. Bilateral self-unbiased learning from biased implicit feedback. In *Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval*, pages 29–39.
- Pan Li and Alexander Tuzhilin. 2020. Ddtcdr: Deep dual transfer cross domain recommendation. In *Proceedings of the 13th International Conference on Web Search and Data Mining*, pages 331–339.
- Tong Man, Huawei Shen, Xiaolong Jin, and Xueqi Cheng. 2017. Cross-domain recommendation: An embedding and mapping approach. In *IJCAI*, volume 17, pages 2464–2470.
- Arshi Naim. 2023. Consumer behavior in marketing patterns, types, segmentation. *European Journal of Economics, Finance and Business Development*, 1(1):1–18.
- Jianmo Ni, Jiacheng Li, and Julian McAuley. 2019. Justifying recommendations using distantly-labeled reviews and fine-grained aspects. In *Proceedings of the 2019 conference on empirical methods in natural language processing and the 9th international joint conference on natural language processing (EMNLP-IJCNLP)*, pages 188–197.

- Xiang-Rong Sheng, Liqin Zhao, Guorui Zhou, Xinyao Ding, Binding Dai, Qiang Luo, Siran Yang, Jingshan Lv, Chi Zhang, Hongbo Deng, et al. 2021. One model to serve all: Star topology adaptive recommender for multi-domain ctr prediction. In *Proceedings of the 30th ACM International Conference on Information & Knowledge Management*, pages 4104–4113.
- Shoujin Wang, Longbing Cao, Yan Wang, Quan Z Sheng, Mehmet A Orgun, and Defu Lian. 2021. A survey on session-based recommender systems. *ACM Computing Surveys (CSUR)*, 54(7):1–38.
- Jiancan Wu, Xiang Wang, Fuli Feng, Xiangnan He, Liang Chen, Jianxun Lian, and Xing Xie. 2021. Self-supervised graph learning for recommendation. In *Proceedings of the 44th international ACM SIGIR conference on research and development in information retrieval*, pages 726–735.
- Ruobing Xie, Qi Liu, Liangdong Wang, Shukai Liu, Bo Zhang, and Leyu Lin. 2022. Contrastive cross-domain recommendation in matching. In *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, pages 4226–4236.
- Jing Yi, Xubin Ren, and Zhenzhong Chen. 2023. Multi-auxiliary augmented collaborative variational auto-encoder for tag recommendation. *ACM Transactions on Information Systems*, 41(4):1–25.
- Junliang Yu, Hongzhi Yin, Xin Xia, Tong Chen, Lizhen Cui, and Quoc Viet Hung Nguyen. 2022. Are graph augmentations necessary? simple graph contrastive learning for recommendation. In *Proceedings of the 45th international ACM SIGIR conference on research and development in information retrieval*, pages 1294–1303.
- Junliang Yu, Xin Xia, Tong Chen, Lizhen Cui, Nguyen Quoc Viet Hung, and Hongzhi Yin. 2023. Xsimgl: Towards extremely simple graph contrastive learning for recommendation. *IEEE Transactions on Knowledge and Data Engineering*.
- Guanghu Yuan, Fajie Yuan, Yudong Li, Beibei Kong, Shujie Li, Lei Chen, Min Yang, Chenyun Yu, Bo Hu, Zang Li, et al. 2022. Tenrec: A large-scale multipurpose benchmark dataset for recommender systems. *Advances in Neural Information Processing Systems*, 35:11480–11493.
- Zheng Yuan, Fajie Yuan, Yu Song, Youhua Li, Junchen Fu, Fei Yang, Yunzhu Pan, and Yongxin Ni. 2023. Where to go next for recommender systems? id- vs. modality-based recommender models revisited. In *Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval, SIGIR '23*, page 2639–2649. Association for Computing Machinery.
- Tianzi Zang, Yanmin Zhu, Haobing Liu, Ruohan Zhang, and Jiadi Yu. 2022. A survey on cross-domain recommendation: taxonomies, methods, and future directions. *ACM Transactions on Information Systems*, 41(2):1–39.
- Peitian Zhang, Shitao Xiao, Zheng Liu, Zhicheng Dou, and Jian-Yun Nie. 2023. Retrieve anything to augment large language models. *arXiv preprint arXiv:2310.07554*.
- Xiaokun Zhang, Bo Xu, Zhaochun Ren, Xiaochen Wang, Hongfei Lin, and Fenglong Ma. 2024. Disentangling id and modality effects for session-based recommendation. *arXiv preprint arXiv:2404.12969*.
- Yi Zhao, Chaozhuo Li, Jiquan Peng, Xiaohan Fang, Feiran Huang, Senzhang Wang, Xing Xie, and Jibing Gong. 2023. Beyond the overlapping users: cross-domain recommendation via adaptive anchor link learning. In *Proceedings of the 46th international ACM SIGIR conference on research and development in information retrieval*, pages 1488–1497.