arXiv:2304.05615v1 [cs.IR] 12 Apr 2023

面向分布外序列推荐的深度稳定多兴趣学习

Qiang Liu，*IEEE*会员，Zhaocheng Liu，Zhenxi Zhu，Shu Wu，*IEEE*高级会员，以及 Liang Wang，*IEEE*会士

摘要——近年来，将用户兴趣提取为多个表示向量的多兴趣模型，在序列推荐中展现出良好的性能。然而，现有的多兴趣推荐模型均未考虑分布外（OOD）泛化问题，在这种情况下，兴趣分布可能会发生变化。由于用户的多种兴趣通常高度相关，模型可能会学习到噪声兴趣与目标物品之间的虚假相关性。一旦数据分布发生变化，兴趣之间的相关性也可能随之改变，而虚假相关性会误导模型做出错误预测。为解决上述分布外泛化问题，我们提出了一种新型多兴趣网络，名为深度稳定多兴趣学习（DESMIL），该网络尝试消除模型所提取兴趣之间的相关性，从而消除虚假相关性。DESMIL 使用注意力模块提取多个兴趣，然后选择其中最重要的一个来做出最终预测。同时，DESMIL 基于希尔伯特-施密特独立性准则（HSIC）引入加权相关性估计损失，并对训练样本赋予权重，以最小化所提取兴趣之间的相关性。我们在分布外和随机设置下进行了大量实验，分别取得了36.8% 和21.7% 的相对提升。

索引词—序列推荐、多兴趣、分布外、稳定学习。

1 引言

SEQUENTIAL 推荐系统旨在基于用户的历史交互，预测用户可能感兴趣的下一个项目。它已成为推荐系统领域的重要研究课题，应用场景包括在线购物、在线视频和餐厅到访等。基于历史行为，准确捕捉用户的动态偏好是序列推荐的核心关注点。如今，已有大量基于循环神经网络 [1], [2], 、卷积神经网络 [3]和注意力网络 [4], [5], [6] 的解决方案被提出。

为了实现准确的序列推荐，我们需要深入分析用户的行为历史，并捕捉他们对不同类型物品的兴趣。同时，用户通常拥有多种兴趣。例如，在在线视频平台上，用户可能同时喜欢观看足球视频、搞笑视频和汽车视频。为了建模用户的多种兴趣，多兴趣网络 [7], [8], [9], [10]已被提出，用多个表示向量对多种兴趣进行编码。然而，现有的多兴趣方法忽略了这样一个事实：兴趣分布在系统中总是在不断变化。这会给多兴趣模型带来分布外（OOD）问题 [11], [12],，当数据分布发生变化时，可能不可避免地损害多兴趣推荐系统的性能。为了明确多兴趣模型中的分布外泛化问题，我们给出定义1—4。

定义 ***1***。（稳定兴趣）给定一个目标物品和用户行为历史，稳定兴趣是那些与目标物品存在因果关系的兴趣。我们将稳定兴趣表示为 （s_0、 s_1、 s_2，.....），并将目标物品表示为 y。那么，上述过程可以表示为 （s_0、 s_1、 s_2，.....） $\rightarrow y$。

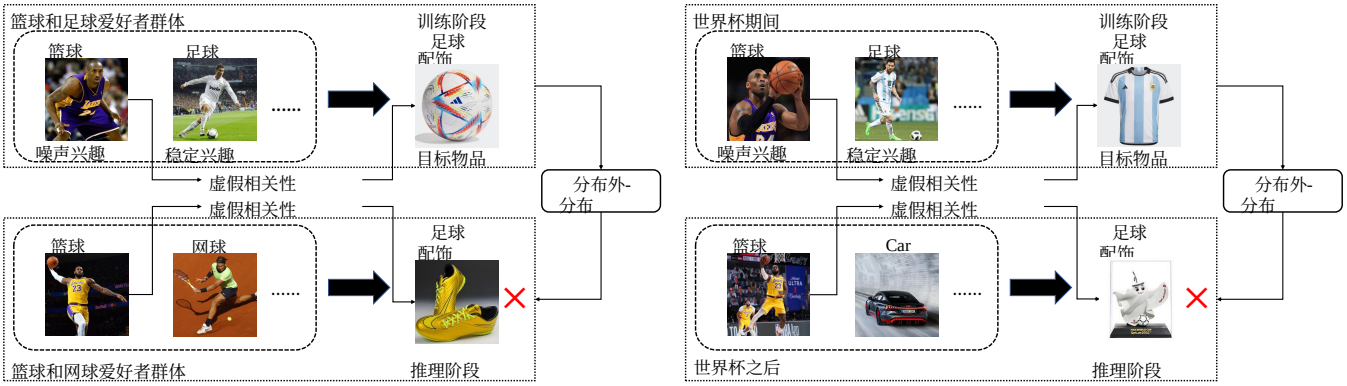
定义***2***。（噪声兴趣）给定一个目标物品和用户行为历史，噪声兴趣是指与目标物品不存在因果关系的兴趣。我们将噪声兴趣表示为 （n_0、 n_1、 n_2，.....）。然后，上述过程可表示为 （n_0、 n_1、 n_2，.....） $\perp y$。此外，稳定兴趣与噪声兴趣之间通常存在不稳定的依赖关系，这可表示为 （s_0、 s_1、 s_2，.....） $\rightarrow$（n_0、 n_1、 n_2，.....）。

定义 ***3***。（不稳定多兴趣模型）给定一个有限的训练集 Ω_{train}，用于进行预测 $\hat{}y$，不稳定多兴趣模型有可能同时学习因果关系 $(s_0, s_1, s_2, ...) \rightarrow \hat{}y$ 和虚假相关性 $(n_0, n_1, n_2, ...) \rightarrow \hat{}y$。不稳定多兴趣模型往往会在分布外环境中失效。虚假相关性源于稳定兴趣与噪声兴趣之间的依赖关系。

定义 ***4***。（稳定多兴趣模型）给定有限的训练集 Ω_{train}，为了进行预测 $\hat{}y$，稳定多兴趣模型学习因果关系$(s_0,s_1,s_2, ...) \rightarrow \hat{}y$，并消除虚假相关，

• *Qiang Liu* 和 *Zhaocheng Liu* 对本研究贡献相同。
• *Qiang Liu*、*Shu Wu* 和 *Liang Wang* 均隶属于中国科学院自动化研究所（*CASIA*）多模态人工智能系统全国重点实验室（*MAIS*）智能感知与计算研究中心（*CRIPAC*），地址：中国北京。电子邮箱：{*qiang.liu, shu.wu, wangliang*}*@nlpr.ia.ac.cn*
• *Zhaocheng Liu* 任职于快手科技，中国北京。电子邮箱：*lio.h.zen@gmail.com*
• *Zhenxi Zhu*就职于南京大学计算机科学与技术系，地址：中国南京。电子邮箱：*zhuzhenxi@smail.nju.edu.cn*

（通讯作者：*Shu Wu*）



(a) 在从篮球和足球球迷群体收集的数据上进行训练，并在从篮球和网球球迷群体收集的数据上进行推理。(b) 在世界杯期间收集的数据上进行训练，并在世界杯之后收集的数据上进行推理。

图 1. 我们展示了两个示例，用于说明多兴趣推荐模型中的分布外泛化问题。传统模型可能会在训练阶段错误地学习噪声兴趣与目标项目之间的虚假相关（图中为篮球和足球配饰），从而在推理阶段误导模型预测。

即，$(n_0, n_1, n_2, ...) \perp \hat{} y$。稳定多兴趣模型要泛化到不同的分布外环境，这是必要的。

兴趣分布的变化可能由以下原因导致：(1) 随着平台的发展，用户分布不断变化，新用户持续出现；(2) 在同一用户群体中，兴趣分布也会因流行趋势或推荐策略的变化而改变。如图 1 所示，我们展示了一些示例。图 1(a) 中的第一个示例涉及两个不同用户群体之间的分布偏移。图 1(b) 中的第二个示例涉及世界杯期间与世界杯之后两个时间段之间的分布偏移，这是一种会影响用户行为的流行趋势。考虑到用户通常具有相对相似的兴趣，从用户行为历史中提取的多个兴趣往往彼此相关。而在线系统倾向于推荐与用户历史兴趣相似的物品，这进一步加剧了稳定兴趣与噪声兴趣之间的依赖关系。在这种依赖关系下，我们不仅可能学习稳定兴趣与目标项目之间的因果关系，还可能学习噪声兴趣与目标项目之间的虚假相关。在图 1 的两个示例中，足球与篮球之间的依赖关系可能会影响模型训练过程，使多兴趣推荐模型学习到篮球与足球配饰之间的虚假相关。稳定兴趣与噪声兴趣之间的依赖关系并不稳定，并且可能在不同的数据分布中发生变化。一旦数据分布发生变化，即用户行为历史中足球与篮球之间的依赖关系发生变化，虚假相关就会使模型在推理阶段产生错误的预测。因此，我们需要研究能够泛化到不同分布外环境的稳定多兴趣推荐模型。

根据上述分析和示例，为缓解多兴趣推荐模型中的分布外泛化问题，我们需要移除稳定兴趣与噪声兴趣之间的依赖关系，这种依赖限制了模型学习稳定兴趣之间的因果关系兴趣和目标项目。为此，可以采用逆倾向加权（IPW）方法 [13], [14], [15], [16]。然而，倾向得分难以准确估计，且估计的方差通常较高 [17]。与此同时，一些研究尝试生成反事实样本，以训练因果模型 [12], [18]。但是，反事实样本生成的质量难以保证，并且这类方法缺乏足够的探索空间。此外，在模型的多种兴趣中，很难准确区分稳定兴趣和噪声兴趣，这使得稳定兴趣与噪声兴趣之间的依赖关系难以消除。为应对上述困难，我们借鉴了稳定学习的思想 [19], [20], [21], [22]。我们无需识别稳定兴趣和噪声兴趣，而是可以消除模型中所有兴趣之间的相关性。为实现这一点，我们可以引入相关性估计损失，并将其与主要目标一同进行优化。

具体而言，本文提出一种新型多兴趣网络，称为深度稳定多兴趣学习（DESMIL）。(1) DESMIL构建了一个基于注意力机制 [23],的多兴趣提取器，并用它从输入的用户行为序列中提取多兴趣表示。(2) 随后，DESMIL从提取出的兴趣中选出最重要的一个作为用户表示，并将其用于生成最终预测以及构建模型训练的主要目标损失。(3) 同时，DESMIL引入了加权相关性估计损失。为了估计提取出的兴趣之间的相关程度，我们采用希尔伯特-施密特独立性准则（HSIC） [24], [25] ，这是一种广泛使用的非线性独立性检验统计量，已应用于特征去相关 [26]。我们为每个样本分配一个权重，并将加权后的HSIC作为加权相关性估计损失。DESMIL通过优化样本权重来最小化加权相关性估计损失。(4) 随后，样本权重也被加入主要目标损失中，从而得到加权主要目标损失。也就是说，兴趣之间相关程度较高的样本在模型训练中的权重往往较低，反之亦然。这使得

多兴趣模型实际上是在一个加权训练数据集上进行训练，其中不同兴趣之间的相关性得以最小化 [27], [28]。(5) 最后，对这两种损失，即加权主要目标损失和加权相关性估计损失，进行迭代优化，直至收敛。为此，DESMIL模型能够更好地学习稳定兴趣与目标项目之间的因果关系。我们在三个真实世界数据集上，分别针对分布外和随机实验设置进行了大量实验，结果表明DESMIL取得了令人鼓舞的效果。

总而言之，本文的主要贡献如下：

- 我们首次分析了多兴趣推荐模型中的分布外泛化问题，并提出对不同兴趣进行去相关处理。这使多兴趣推荐模型能够学习稳定兴趣与目标物品之间的因果关系，并消除噪声兴趣与目标物品之间的虚假相关。
- 我们提出了一种新颖的 DESMIL 模型，用于学习序列推荐中的稳定表示，并在分布外环境中实现稳定且准确的预测。
- 大量实验表明，我们提出的 DESMIL 模型显著优于多种先进的序列推荐模型，尤其是在分布外设置下。

本文其余部分安排如下。第 2 节回顾序列推荐、深度多兴趣模型和稳定学习方面的相关工作。随后，我们在第 3 节分析多兴趣推荐模型的因果视角，并介绍非线性相关性估计的统计判据。第 4 节详细介绍我们提出的 DESMIL 模型。第 5 节通过实证实验验证 DESMIL 的有效性。第 6 节总结全文。

2 相关工作

本节将回顾序列推荐、深度多兴趣模型和稳定学习方面的一些研究工作。

2.1 序列推荐

从历史行为中建模用户的动态偏好是序列推荐研究的核心问题 [29]，而序列推荐是推荐系统中的一项主要任务。在一些传统模型中 [30], [31], [32], [33]，，马尔可夫链和矩阵分解被用于建模历史行为。最具代表性的模型是 FPMC [30]，它采用个性化马尔可夫链，并通过分解模型训练模型，以捕获协同信息。近年来，各种深度神经网络，如循环神经网络 [1], [2], [34], [35], [36]、卷积神经网络 [3], [37]和基于注意力的网络 [4], [5], [6], [38], [39], [40], [41]，已被应用于深度序列推荐模型中。针对推荐的目标感知注意力机制也得到了研究 [42], [43]。最近，对比学习已被应用于序列推荐 [44], [45], [46], [47], 以应对数据中的稀疏性和噪声。同时，一些研究 [48], [49], [50] 尝试利用多样化的信息进行序列推荐。

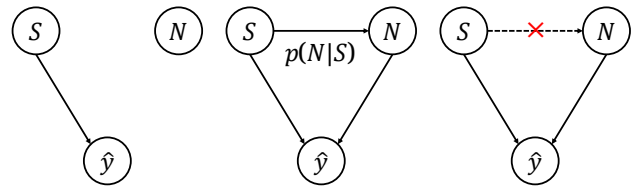
与此同时，研究者也开始运用因果推断来增强因果性并消除推荐中的偏差 [13], [14], [16], [17], [18], [51], [52], [53], [54]。其中，曝光偏差 [13], [14], [53], [55]和流行度偏差 [17], [56] 等偏差在静态推荐系统中得到了广泛研究。用户人口统计特征偏移问题也通过因果表示学习在协同过滤场景下得到了研究 [52]。对于序列推荐，研究者同样研究了曝光偏差，以应对用户行为历史中的非随机缺失问题 [16]，[57], [58]。此外，一些研究工作 [12], [18], [59] 在序列用户行为历史中生成反事实样本，以训练能够泛化到分布外环境的模型。

2.2 深度多兴趣模型

在实际场景中，用户的历史行为可能反映出多个兴趣，而多数模型采用的整体用户偏好表示很难捕捉用户兴趣的多样性本质 [9], [60]。因此，我们需要从用户的历史行为中提取多个兴趣，以实现更好的序列推荐。已有一些研究 [7], [8], [9], [10], [61], [62] 探讨如何在序列推荐中将用户的多个兴趣有效提取为多个向量。MIND [7] 率先提出了一种基于动态路由机制 [63]，[64], [65]的多兴趣提取器。由于动态路由过程可以视为软聚类，因此用户的历史行为可以被划分为不同的簇。此外，研究还提出了一种标签感知注意力机制，以便在训练过程中有效聚合多个用户偏好表示。除此之外，ComiRec [8] 提出了一种可控的多兴趣框架，其中可以采用动态路由和注意力模型来提取用户的多个兴趣。近期，SINE [9] 不再通过对用户行为进行聚类来隐式生成用户的多个兴趣，而是直接维护一组概念原型，以表示用户所有潜在兴趣。然后，利用自注意力机制确定哪些原型会被激活，成为用户的多个兴趣。MGNM [10]提出将多兴趣学习模型与图卷积网络相结合。通过聚合多层次的用户偏好，MGNM能够更准确地提取用户的多个兴趣。与此同时，多兴趣模型中的用户感知候选匹配也得到了研究 [66]。

2.3 稳定学习

分布外问题 [11] 是现实场景中常见的挑战，而稳定学习近来已成为应对这一问题的有效方法。稳定学习旨在学习一个稳定的预测模型，使其在任意未知测试数据 [20]上都能取得均衡良好的性能。大多数稳定学习工作的框架可分为两个步骤：样本权重学习和加权训练。具体而言，首先学习样本权重，以消除训练数据中特征间的相关性；然后进行加权训练，在加权后的特征分布上训练模型，这是一种使特征分布满足独立同分布假设的方法。沿着这一研究方向，各种去相关



(a) 理想因果图——图。 (b) 传统模型的因果图。传统模型。 (c) 移除依赖 $S \to N$。

图 2. 多兴趣推荐模型的因果视角分析。

方法 [19], [20], [21], [22] 已被提出，用于学习样本权重并训练线性稳定模型。此外，StableNet [27] 提出采用随机傅里叶特征来消除卷积神经网络中特征之间的非线性依赖。图神经网络 [28], [67], [68]和医疗健康领域 [69]中的特征去相关也得到了研究。近期，Xu 等人 [70]从理论上证明，在温和条件下，特征变量相互独立即可保证最小二乘回归和二元分类的稳定性。

3 预备知识

本节分析多兴趣推荐模型的因果视角，并介绍用于非线性相关性估计的统计准则。

3.1 多兴趣模型的因果视角

在图 2 中，我们展示了多兴趣序列推荐的因果图。 S = （s_0、 s_1、 s_2.....）、N = （n_0、 n_1、 n_2.....）和 $\hat{}y$分别表示稳定兴趣、噪声兴趣和目标物品的预测结果。图 2(a) 是理想的因果图，其中仅存在因果关系$S \to \hat{}y$ 。然而，如图 2(b) 所示，存在依赖关系$S \to N$，导致传统的多兴趣推荐模型学习到虚假相关性 $N \to \hat{}y$。依赖关系 $S \to N$并不稳定， p （$N|S$）可能会在不同环境中发生变化。一旦训练阶段与推理阶段（验证或测试）之间的数据分布发生变化，就会出现 p_{train} （$N|S$） $\neq p_{\text{infer}}(N|S)$，而虚假相关性 $N \to \hat{}y$ 会误导模型做出错误的预测。在图 1 中可以找到用于展示上述现象的示例。因此，路径$N \leftarrow S \to \hat{}y$ 建立了虚假相关性 $N \to \hat{}y$。因此，如图 2(c) 所示，我们需要移除 $S \to N$，从而消除虚假相关性 $N \to \hat{}y$ ，并准确学习因果关系 $S \to \hat{}y$ 。

然而，很难从模型中的多个兴趣中准确区分稳定兴趣和噪声兴趣。因此，很难直接对 S 和 N进行兴趣去相关。受稳定学习[19], [20], [21], [22], 的启发，稳定学习通过样本重新加权消除所有输入特征之间的相关性，我们可以消除这些相关性。

推荐模型中的所有兴趣。也就是说，我们可以估计每对兴趣之间的相关程度，并最小化总体相关程度。此外，考虑到两个兴趣表示向量之间的相关性应大小规律

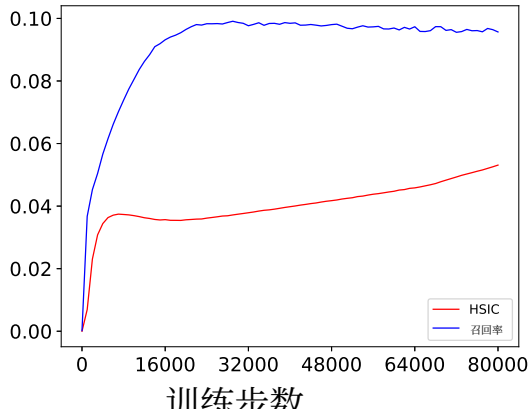


图3. 在 Book 数据集上训练 ComiRec 期间，训练集上的 HSIC 值和验证集上的 Recall@50 值曲线。从曲线的后半部分可以看出，兴趣之间过度的相关性限制了性能的进一步提升。

是非线性的，我们需要一个非线性相关性估计准则。

3.2 相关性估计准则

由于我们需要最小化模型中多个兴趣之间的相关性，因此必须估计每对兴趣之间非线性相关性的程度。为此，我们采用 HSIC [24], [25], 作为相关性估计准则。HSIC 可以估计两个变量之间的非线性相关性，并已用于特征去相关 [26], 。HSIC 是再生核希尔伯特空间（RKHS）中分布之间互协方差算子的希尔伯特-施密特范数。

给定两个随机变量 U 和 V，HSIC 的公式为:

$$\begin{aligned} HSIC(U,V) = &\mathbb{E}_{uu'vv'}[k_u(u,u')k_v(v,v')] \\ &+ \mathbb{E}_{uu'}[k_u(u,u')]\mathbb{E}_{vv'}[k_v(v,v')] \\ &- 2\mathbb{E}_{uv}[\mathbb{E}_{u'}(k_u(u,u'))\mathbb{E}_{v'}[k_v(v,v')]], \end{aligned} \tag{1}$$

其中， $\mathbb{E}_{uu'vv'}$ 表示从 $P(U,V)$中抽取的独立样本对 (u,v) 和 (u',v') 上的期望， k_u和 k_v是核函数。我们使用径向基函数（RBF）核，其公式为:

$$k(u,v) = exp\left(-\frac{||u-v||_2^2}{\sigma^2}\right). \tag{2}$$

给定从 $P(U,V)$ 中抽取的 m 个样本，经验希尔伯特-施密特独立性准则[24] 定义为

$$HSIC(U,V) = (m-1)^{-2}tr(\mathbf{K}_U\mathbf{P}\mathbf{K}_V\mathbf{P}), \tag{3}$$

其中 $\mathbf{K}_U \in \mathbb{R}^{m\times m}$ 和 $\mathbf{K}_V \in \mathbb{R}^{m\times m}$ 的元素分别为 $\mathbf{K}_{U_{ij}} = k\ U_i\ U_j$ $\mathbf{K}_{V_{ij}} = k\ V_i\ V_j$ $\mathbf{P} = \mathbf{I} - \frac{1}{m}\mathbf{1}\mathbf{1}^{\mathrm{T}} \in \mathbb{R}^{m\times m}$ $\underline{\quad}(,)$ 和 $\mathbf{K}(,)$，$\mathbf{P}$ $\mathbf{I}$ 是中心化矩阵，而 $\mathbf{1}$ 是一个 $(m\times 1)$ 维全 $\mathbf{1}$ 向量。值得注意的是， $HSIC(U,V)$ $= 0$ 当且仅当 $U \perp V$。

此外，为了研究提取出的兴趣之间的相关性对多兴趣推荐模型训练过程的影响，图3展示了在 Book 数据集 [71], [72]上训练 ComiRec [8] 时，训练集上的 HSIC 值和验证集上的 Recall@50 值的变化。HSIC 值是通过对每对从 ComiRec 中提取的兴趣表示之间的非线性相关性进行 HSIC 测量并求和得到的

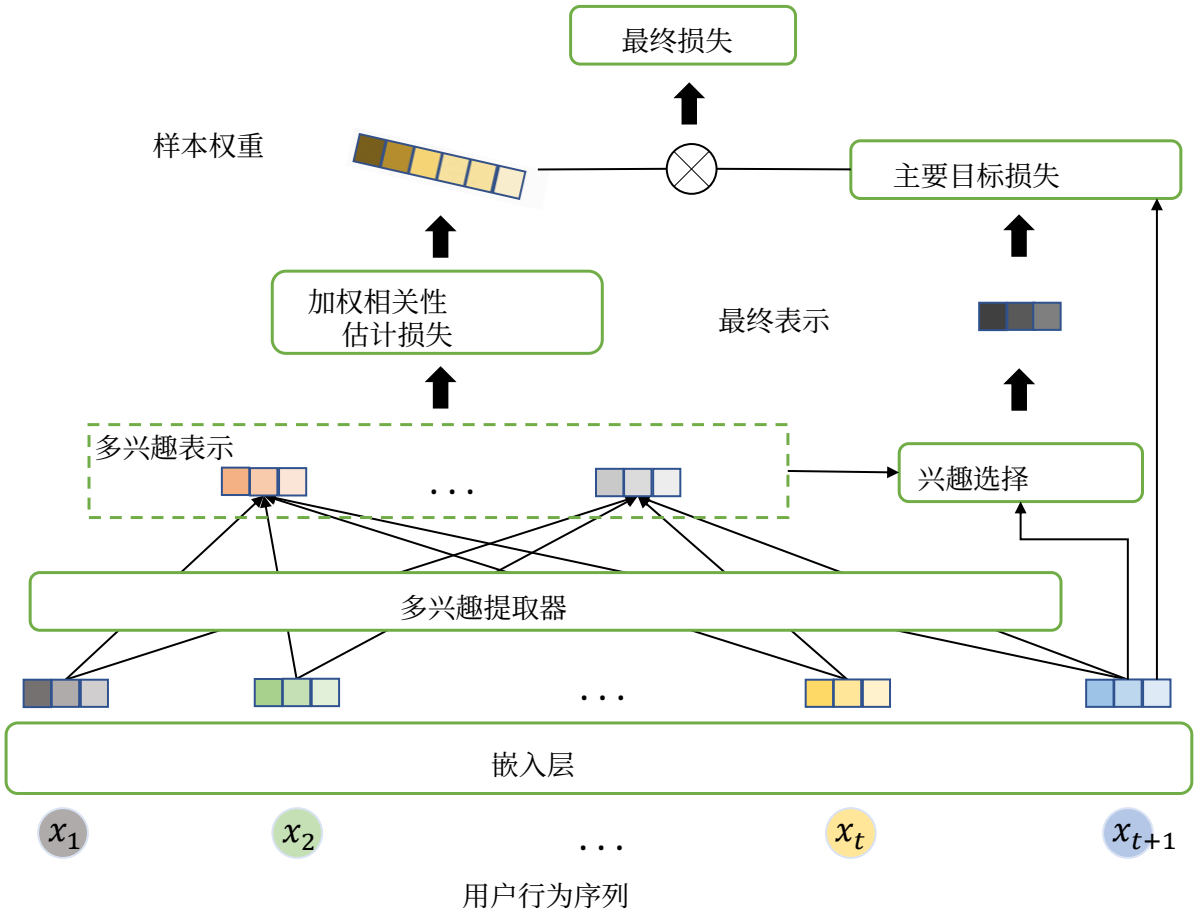


图 4。我们提出的DESMIL模型概览。DESMIL 提取多兴趣表示，并选择其中最重要的一个来生成最终预测并构建主要目标损失。同时，DESMIL基于HSIC 引入加权相关性估计损失，对训练样本进行加权，以最小化所提取兴趣之间的相关性。

。从曲线中可以观察到，大约经过 2000 步后，HSIC 值持续缓慢上升，而 Recall@50 值停止增长，甚至开始下降。也就是说，在曲线后半段，兴趣之间过强的相关性限制了性能的进一步提升。在某种程度上，对于多兴趣模型，上述观察揭示了兴趣之间的相关性与模型性能之间的权衡。

4 方法论

本节将对问题进行形式化，并详细介绍所提出的 DESMIL 模型。DESMIL 的总体概览如图 4 所示。

4.1 问题定义

在序列推荐场景中，我们有一组用户 $\mathcal{U} = \{u_1, u_2, \cdots, u_{|\mathcal{U}|}\}$ 和一个物品全集$\mathcal{I} = \{i_1, i_2, \cdots, i_{|\mathcal{I}|}\}$。对于每个用户 u，给定截至时间步 t 的行为序列 $X^u = (x_1^u, x_2^u, \cdots, x_t^u)$，我们需要预测用户的下一次交互 x_{t+1}^u，其中 $x_t^u \in \mathcal{I}$。序列推荐的目标是为每位用户推荐一份物品列表，使其未来需求最大化。同时，在多兴趣模型中，每位用户都有多个兴趣表示，我们用 c 表示模型中的兴趣表示向量数量。

4.2 多兴趣表示提取

首先，我们将行为序列中的物品嵌入为稠密向量。具体而言，给定输入序列 $(x_1^u, \cdots, x_t^u)$，我们创建嵌入矩阵 $\mathbf{V} \in \mathbb{R}^{|\mathcal{I}| \times d}$，其中 d 表示嵌入维度，并通过嵌入查找操作获取输入嵌入矩阵。此外，为了让所提出的 DESMIL 感知历史物品的位置，我们将相应的可训练位置嵌入矩阵 [5], [23] $\mathbf{P} \in \mathbb{R}^{t \times d}$ 注入输入嵌入矩阵。最终的输入嵌入矩阵$\mathbf{E}_t^u \in \mathbb{R}^{t \times d}$ 可表示为

$$\mathbf{E}_t^u = \begin{bmatrix} \mathbf{V}_{x_1^u} + \mathbf{P}_1 \\ \vdots \\ \mathbf{V}_{x_t^u} + \mathbf{P}_t \end{bmatrix}. \tag{4}$$

接下来，我们需要一个多兴趣提取器，生成多个表示向量，以捕捉用户的多样化兴趣。鉴于具体的兴趣提取方法并非我们关注的重点，且本文的主要目标是从多兴趣表示中学习因果表示，以实现分布外泛化，我们通过经验采用了一种

算法 1DESMIL 的训练过程

输入： 训练集 Ω_{train}，以及最大训练轮数$Epoch$。

输出：模型参数 θ。1：初始化迭代变量 $q \leftarrow 0$。2：初始化最佳迭代变量 $q_{best} \leftarrow 0$。3：为所有 u 和 t初始化样本权重 $\omega_u^{(0)}{}_{,t} = 1.0$。4：通过Glorot 均匀初始化器 [75]初始化模型参数 $\theta^{(0)}$。

5: **重复**

6：抽取一批样本 $\mathcal{B}$。 7：$q \leftarrow q + 1$。 8：固定 $\omega_{\mathcal{B}}^{(q-1)}$，并通过更新$\theta^{(q)}$来最小化$\hat{\mathcal{L}}^{(q)}{}_{\text{main}}$，其中$\hat{\mathcal{L}}^{(q)}{}_{\text{main}}$ 定义见公式（9）。 9：固定 $\theta^{(q)}$，并按照公式（12）通过最小化 $\mathcal{L}_{\text{corr}}^{(q)}$ 来更新 $\omega_{\mathcal{B}}^{(q)}$，其中 $\mathcal{L}_{\text{corr}}^{(q)}$ 定义见公式（11）。 10：如果取得更好的验证结果，则更新 $q_{best} \leftarrow q$。 11：**直到** 提前停止或达到最大训练轮数。 12：**返回** $\theta^{(q_{best})}$。

简单的注意力模块。注意力矩阵$\mathbf{A}_t^u \in \mathbb{R}^{c\times t}$可计算为

$$\mathbf{A}_t^u = \text{softmax}(\mathbf{W}_2 \tanh(\mathbf{W}_1(\mathbf{E}_t^u)^\top)), \tag{5}$$

其中，$\mathbf{W}_1 \in \mathbb{R}^{d\times d}$ 和$\mathbf{W}_2 \in \mathbb{R}^{c\times d}$是可训练的变换矩阵。然后，我们得到多兴趣表示矩阵$\mathbf{M}_t^u \in \mathbb{R}^{c\times d}$，其计算方式为

$$\mathbf{M}_t^u = \mathbf{A}_t^u \mathbf{E}_t^u. \tag{6}$$

为此，对于每个用户，我们获得 c 个表示向量，以捕捉其多样化的兴趣。

此外，我们采用兴趣选择策略 [8]，从捕捉到的兴趣中选出最重要的兴趣表示，以生成整个行为序列的最终表示。给定待预测的 x_{t+1}^u 及其嵌入$\mathbf{V}^{x_{t+1}^u}$，我们将选定的表示$\mathbf{R}_t^u \in \mathbb{R}^{1\times d}$ 生成为

$$\mathbf{R}_t^u = \mathbf{M}_t^u[argmax(\mathbf{M}_t^u \mathbf{V}_{x_{t+1}^u}^\top), :]. \tag{7}$$

最后，对于从训练集Ω_{train}中抽取的一批样本 $\mathcal{B}$，主要目标损失可表示为

$$\mathcal{L}_{\text{main}} = -\sum_{(u,t)\in\mathcal{B}} log\left(\frac{exp(\mathbf{R}_t^u \mathbf{V}_{x_{t+1}^u}^\top)}{\sum_{i\in\mathcal{I}} exp(\mathbf{R}_t^u \mathbf{V}_i^\top)}\right), \tag{8}$$

考虑到计算效率，可通过采样 softmax 技术 [73], [74] 实现。

4.3 多兴趣表示之间的去相关

如第 3 节所述，我们采用样本重新加权技术 [19], [21], [27] 来降低多兴趣表示之间的相关性。我们提出了一种兴趣去相关正则化器，旨在为每个样本估算一个权重，从而最大限度地降低多个兴趣之间的相关性。具体而言，我们为每个样本分配一个权重 $\omega_{u,t}$。我们用 $\omega_u^{(q)}{}_{,t}$ 表示重新加权后的样本权重。第 q 个训练轮次的计算，以及初始样本权重为 $\omega_u^{(0)}{}_{,t} = 1.0$。

为了对多兴趣表示进行去相关，我们对式（8）中样本的主要目标损失重新加权，并得到第 q 个 epoch 的修订加权主要目标损失:

$$\hat{\mathcal{L}}_{\text{main}}^{(q)} = -\sum_{(u,t)\in\mathcal{B}} \omega_{u,t}^{(q-1)} log\left(\frac{exp(\mathbf{R}_t^u \mathbf{V}_{x_{t+1}^u}^\top)}{\sum_{i\in\mathcal{I}} exp(\mathbf{R}_t^u \mathbf{V}_i^\top)}\right), \tag{9}$$

该方法使用上一轮优化得到的样本权重对模型训练过程进行重新加权，其最终损失如图 4 所示。

与此同时，我们需要通过最小化多个兴趣之间的相关程度来估计样本权重。取自上一轮训练的权重后，用户 u 在时间步 t 后的多兴趣表示被重新加权为

$$\hat{\mathbf{M}}_{u,t}^{(q)} = \omega_{u,t}^{(q-1)} \mathbf{M}_t^u. \tag{10}$$

然后，我们提出了一种加权相关性估计损失，该损失基于第 3.2 节介绍的 HSIC，用于估计多个兴趣之间的相关程度，如

$$\mathcal{L}_{\text{corr}}^{(q)} = \sum_{(u,t)\in\mathcal{B}} \sum_j \sum_k \lambda HSIC(\hat{\mathbf{M}}_{u,t}^{(q)}[j,:], \hat{\mathbf{M}}_{u,t}^{(q)}[k,:]), \tag{11}$$

其中，λ 是控制样本权重学习过程的去相关重要性。然后，通过最小化相关程度，我们优化样本权重

$$\omega_{\mathcal{B}}^{(q)} = \underset{\omega}{argmin}\, \mathcal{L}_{\text{corr}}^{(q)}. \tag{12}$$

此外，我们交替优化样本权重 $\omega^{(q)}$，以最小化加权主要目标损失 $\hat{\mathcal{L}}^{(q)}{}_{\text{主要}}$，并优化模型参数 $\theta^{(q)}$，以最小化加权相关性估计损失 $\mathcal{L}_{\text{corr}}^{(q)}$。同时，我们提出的 DESMIL模型的详细流程如算法 1 所示。

通过上述训练过程，兴趣之间相关程度较高的样本在主要目标损失中的模型训练权重会较低，反之亦然。因此，最终模型实际上是在加权训练数据集上进行训练的，其中根据公式 (11) 中的损失，尽可能减小不同兴趣之间的相关性。需要注意的是，样本权重仅使用训练集中的样本进行优化，这有助于最终模型泛化到分布外环境。DESMIL 的推理过程与传统的多兴趣模型相同，无需为验证集或测试集中的样本估计样本权重。

5 实验

本节将通过大量实验评估我们提出的 DESMIL模型的性能。我们需要回答以下研究问题（RQ）：

- **RQ1：** DESMIL 在分布外环境下的性能如何?
- **RQ2：** DESMIL 在普通分布内环境下的表现如何?

表1 不同指标（%）评估下，采用分布外数据划分的结果。最佳表现以粗体标示，最强的基线方法以下划线标示。改进幅度表示 DESMIL 相较于最佳基线方法的相对提升。

数据集	指标	GRU4Rec	SASRec	MIND	ComiRec	SINE	MGNM	USR	CauseRec	DESMIL	改进
Book	Recall@20	3.24	4.95	5.36	5.60	5.54	5.32	5.42	5.38	**7.16**	27.86%
	Recall@50	5.84	6.78	7.10	7.96	7.56	7.35	7.65	7.71	**10.89**	36.81%
	NDCG@20	2.87	3.06	3.13	3.20	3.41	3.46	3.55	3.25	**4.25**	19.72%
	NDCG@50	3.15	3.54	3.96	3.78	4.22	4.15	4.30	4.08	**5.30**	23.26%
	HR@20	6.93	8.25	9.98	10.25	10.17	10.26	10.31	10.48	**12.42**	18.51%
	HR@50	12.10	13.56	15.98	15.84	15.86	15.74	15.48	16.04	**18.27**	13.90%
电影和电视	Recall@20	10.87	12.34	13.14	13.65	13.64	13.79	13.46	13.90	**14.62**	5.18%
	Recall@50	14.08	15.01	16.18	16.57	16.68	17.17	16.50	17.33	**18.65**	7.62%
	NDCG@20	9.87	11.00	11.99	12.71	12.53	12.61	12.25	12.91	**13.87**	7.44%
	NDCG@50	11.85	12.72	13.54	13.92	13.77	13.76	13.16	14.40	**15.44**	7.22%
	HR@20	19.25	20.11	22.36	23.32	23.27	23.17	22.88	23.44	**23.77**	1.41%
	HR@ 50	25.20	26.35	28.56	29.84	29.71	29.75	29.10	30.05	**31.00**	3.16%
CD与黑胶唱片	Recall@20	4.15	6.37	7.16	7.26	7.33	7.25	6.96	7.48	**8.20**	9.63%
	Recall@50	5.88	8.80	9.92	10.26	10.18	10.20	10.03	10.50	**11.41**	8.67%
	NDCG@20	4.31	5.26	5.90	5.82	6.02	5.92	5.80	6.15	**6.82**	10.89%
	NDCG@50	5.04	6.17	6.85	6.35	6.78	6.54	6.64	6.92	**7.67**	10.84%
	HR@20	7.21	10.57	12.35	12.23	12.28	12.26	11.87	12.16	**13.45**	8.91%
	HR@50	10.87	15.60	17.36	17.05	17.34	17.24	17.10	17.15	**19.36**	10.63%

- **RQ3：** DESMIL模型是否对某些重要超参数敏感?
- **RQ4：**DESMIL模型如何影响训练过程?
- **RQ5：**DESMIL模型中的样本权重分布是如何学习的?

5.1 实验数据集

我们在三个从真实场景中收集的公开数据集上进行了实验对比：

- **Book数据集**。Book 数据集是亚马逊产品数据[1] [71], [72] 中“图书”类别的一部分。共有 603,668 名用户、367,982 个项目和总计 8,898,041 条用户行为。
- **电影和电视数据集**。电影和电视数据集是亚马逊评论数据[2] [76]更新版本的一部分。该数据集共有 304,763 位用户、89,590 个项目和 3,506,470 条用户行为。
- **CD和黑胶唱片数据集**。CD和黑胶唱片数据集也是更新后的亚马逊评论数据的一部分。该数据集总共有129,237名用户、145,522件商品和1,682,049条用户行为。

此外，我们不仅需要在分布外环境中进行性能比较，以验证分布外泛化能力，还需要在分布内环境中进行性能比较，以验证普通推荐能力。因此，我们执行两种不同的数据划分：

(1) 第一种划分是**分布外数据划分**。如图 1 中的示例所示，不同的用户群体和流行度趋势往往会导致数据分布偏移，并影响推荐性能。考虑到在离线数据集中难以识别流行度趋势，我们根据不同的用户群体构建分布外数据。实践中，我们使用不同用户所涉及物品的 Jaccard 相似度[3] 来衡量用户之间的相似度。我们随机选择一名用户，然后迭代地选择与已选用户相似度最高的下一名用户，直到选出50%的用户。由此得到一组已选用户 $\mathcal{U}_1$ 和一组剩余用户 $\mathcal{U}_2$。这样， $\mathcal{U}_1$ 和 $\mathcal{U}_2$ 具有截然不同的分布，其中 $\mathcal{U}_1$ 可视为 $\mathcal{U}_2$ 的分布外环境。接着，我们随机将 $\mathcal{U}_1$中的10% 、 $\mathcal{U}_2$ 中的10% 以及其他互不重叠的$\mathcal{U}_2$ 中的80% 分别用作测试集、验证集和训练集。也就是说，训练集、验证集和测试集的样本数量比例为$8:1:1$。

表 2 在分布外数据划分下，DESMIL、MGNM+PW 和 ComiRec+PW 的 Recall@50（%）对比。最佳表现以粗体标示。

方法	Book	电影和电视	CD与黑胶唱片
ComiRec+PW	8.63	17.16	10.25
MGNM+PW	8.14	17.54	10.33
DESMIL	**10.89**	**18.65**	**11.41**

(2) 第二种划分是**随机数据划分**。我们采用先前工作 [8],中的相同划分方式，将样本随机划分为训练集、验证集和测试集。

5.2 对比基线方法

我们将提出的 DESMIL 模型与以下基线方法进行比较评估：

- **GRU4Rec** [2]: 一种经典的、基于循环神经网络的序列推荐模型。
- **SASRec** [5]: 一种先进的序列推荐模型，采用注意力机制网络进行序列推荐。
- **MIND** [7]: 一种经典的多兴趣序列网络，通过动态路由在匹配阶段对用户的多样化兴趣进行建模。
- **ComiRec** [8]: 一种最先进的序列网络，配备多兴趣提取模块，用于生成

1. http://jmcauley.ucsd.edu/data/amazon/ 2. https://nijianmo.github.io/amazon/index.html 3. https://www.learndatasci.com/glossary/jaccard-similarity/

表 3 随机数据划分下使用不同指标（%）进行评估的结果。最佳性能以粗体标示，最强基线方法加下划线。改进幅度表示 DESMIL 相较于最佳基线方法的相对提升。

数据集	指标	GRU4Rec	SASRec	MIND	ComiRec	SINE	MGNME	USR	CauseRec	DESMIL	改进
Book	Recall@20	3.47	4.76	5.10	5.92	5.46	6.18	5.75	5.24	**7.52**	21.68%
	Recall@50	6.50	7.78	7.64	9.35	8.72	9.64	8.60	9.36	**11.06**	14.73%
	NDCG@20	3.55	4.84	5.09	4.17	4.83	4.88	4.93	4.66	**5.46**	7.27%
	NDCG@50	4.42	5.74	5.97	5.47	6.04	6.19	5.95	6.28	**7.24**	15.29%
	HR@20	7.84	8.82	10.59	11.70	11.87	12.70	11.28	12.45	**14.86**	17.01%
	HR@50	12.38	13.79	15.56	18.04	18.94	20.21	17.89	20.23	**21.53**	6.43%
电影和电视	Recall@20	13.20	14.43	14.87	15.46	15.16	15.50	14.76	15.30	**15.76**	1.68%
	Recall@50	17.66	18.27	19.55	18.87	19.30	19.14	19.27	19.24	**20.90**	6.91%
	NDCG@20	15.07	14.49	**15.80**	14.73	15.57	15.44	14.90	15.10	15.54	-
	NDCG@50	16.21	16.72	17.23	16.17	16.64	16.68	16.81	16.83	**17.36**	0.75%
	HR@20	22.67	23.25	25.34	25.87	25.12	25.76	24.75	25.94	**26.42**	1.85%
	HR@50	29.54	30.43	32.93	33.68	33.30	33.95	32.90	33.90	**34.80**	2.50%
CD与黑胶唱片	Recall@20	4.39	6.92	7.55	7.96	7.69	8.03	7.35	7.77	**8.75**	8.97%
	Recall@50	6.07	8.52	10.32	11.23	10.93	11.32	10.57	11.12	**12.09**	6.80%
	NDCG@20	4.81	6.44	**7.93**	6.84	7.28	7.46	7.12	7.51	7.86	-
	NDCG@50	5.42	7.10	8.88	8.01	8.34	8.68	8.18	8.57	**8.91**	0.34%
	HR@20	8.47	12.86	14.28	14.35	14.55	14.60	14.08	14.49	**15.73**	7.74%
	HR@50	11.79	16.29	19.38	20.26	20.71	20.83	19.80	20.66	**21.89**	5.09%

多个用户兴趣，并通过聚合模块获取排名前 N 的物品。我们采用 ComiRec 的 SA 设置，原论文中将其称为 ComiRec-SA。

- **SINE** [9]：一种最先进的多兴趣模型，维护一个概念原型池，以表示用户潜在兴趣的完整集合，并使用自注意力机制来决定哪些原型被激活为用户的多个兴趣。

- **MGNM** [10]：一种先进的多兴趣模型，与基于图卷积网络的推荐系统相结合。

- **USR** [16]：一种最先进的去偏序列推荐模型，在基于 IPW 的框架中引入潜在混杂因素，以处理用户交互历史中的曝光偏差。

- **CauseRec** [12]：一种先进的序列网络，通过对比式用户表征学习来建模反事实数据分布，从而泛化到分布外环境。

我们在分布外和随机数据划分设置下，将上述基线方法与 DESMIL 进行比较。此外，我们还考虑了一种基于 IPW 的去偏方法，称为置换加权（PW） [15]。我们在两个具有代表性的多兴趣模型 ComiRec 和 MGNM 上应用 PW，得到**ComiRec+PW** 和 **MGNM+PW** ，以便在分布外环境中与 DESMIL 进行性能比较。

5.3 实验设置

在本小节中，我们介绍实验设置的一些细节。

5.3.1 参数配置

物品的嵌入大小为 64。根据 ComiRec 的最佳性能，Book 数据集的批量大小为 1024，而其他两个数据集的批量大小为 128。采样 softmax 损失的负样本数量为 10。所有模型均基于 Recall@50 使用提前停止。在验证集上。去相关重要性和兴趣数量分别在 $\{0.01, 0.1, 1.0, 10.0, 100.0\}$ 和 $\{2, 4, 6, 8\}$的范围内进行调优。我们使用学习率为 lr = 0.001 的 Adam 优化器进行优化。

5.3.2 评估指标

我们使用 top-p 召回率、归一化折损累计增益（NDCG）和命中率（HR）来评估所有对比模型的性能。我们在实验中选择了 $p = 20,50$。这三个指标依据不同标准衡量模型性能。Recall@p 定义为在前 p 个推荐项目中找到的相关项目所占比例。NDCG@p 进一步考虑增益的归一化以及正确推荐项目的排序，其中相关性更高的项目对最终得分影响更大。HR@p 定义为在前 p 个推荐项目中找到测试集内项目的比例。

5.4 分布外数据划分下的结果（RQ1）

在表1中，我们展示了在分布外数据划分下的实验对比结果。在参与比较的基线方法中，CauseRec 表现最佳，在 18个目标指标中的 12 个指标上取得了最佳性能。这表明，在一定程-度上，使用反事实样本进行训练可以提升模型的分布外泛化能力。USR 的表现优于单兴趣模型，并且能够与多兴-趣模型相竞争。考虑到USR中的推荐骨-干网络是一个简单的单兴趣GRU，这说明了基于逆倾向加权的方法的有效性。在多兴-趣模型中，简单模型，即 MIND和ComiRec，似乎表现相对更好。这表明，结构更简单的模型往往能在不同的分布外环境中取得更好的表现。此外，我们提出的 DESMIL模型明显大幅领先于所有参与比较的基-线方法。

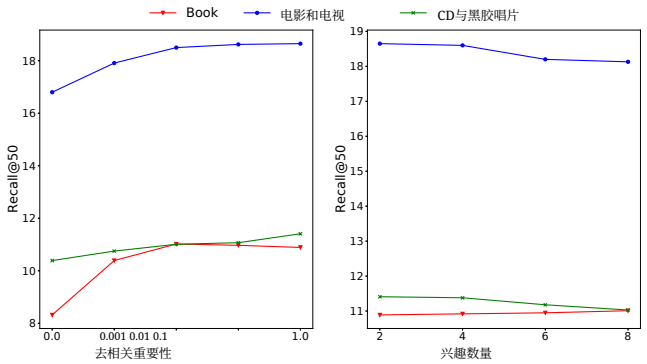


图 5. 分布外数据划分下去相关重要性系数和兴趣数量的超参数研究，以 Re-call@50(%) 衡量。

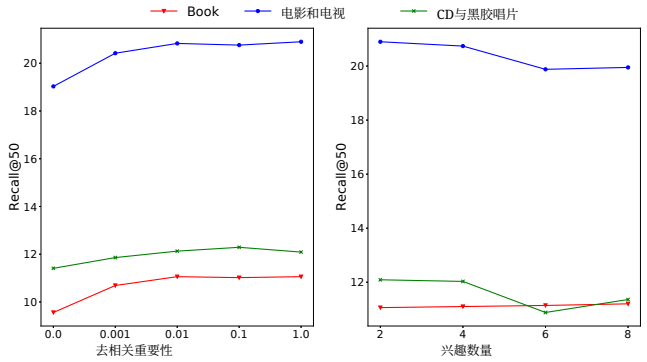


图 6. 在随机数据划分下，去相关重要性系数和兴趣数量的超参数研究，采用 Re-call@50(%) 进行衡量。

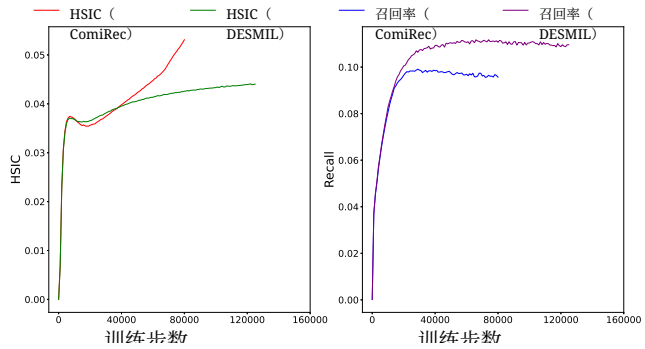


图 7. 在 Book 数据集上训练 ComiRec 和 DESMIL 时，训练集上的 HSIC 与验证集上的 Recall@50 曲线。与 ComiRec 相比，DESMIL 中多个兴趣之间的相关性更弱（由 HSIC 衡量），性能则更好（由 Recall@50 衡量）。

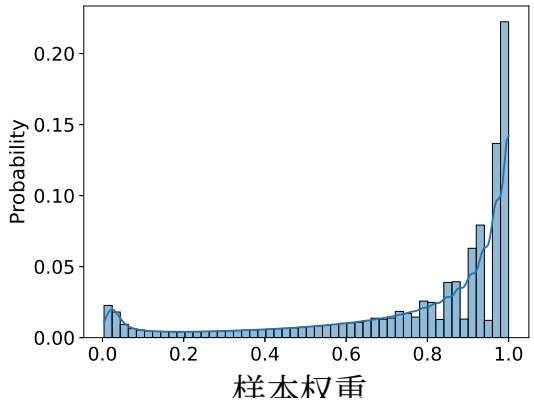


图 8. 在 Book 数据集上训练的 DESMIL模型中样本权重的分布。

同时，我们在表2中针对分布外数据划分，对DESMIL、MGNM+PW和ComiRec+PW进行了比较。在所比较的基线方法中，我们可以观察到，ComiRec+PW在Book 数据集上表现更好，而MGNM+PW在CD和黑胶唱片数据集以及电影和电视数据集上表现更好。与表1中的结果相比，MGNM+PW和ComiRec+PW的表现分别优于MGNM和ComiRec，并且与CauseRec相比具有竞争力。这进一步表明，基于逆倾向加权的方法 [13], [14], [15]对于分布外泛化是有效的。与此同时，DESMIL仍然显著优于上述两种PW增强方法。这些结果和观察充分证明了DESMIL在分布外环境中的有效性和稳定性。

5.5 随机数据划分下的结果（RQ2）

随机数据划分下的实验比较结果如表3所示。我们可以观察到，表1中的结果通常低于表3中的结果，这表明分布偏移导致了更困难的任务。总体而言，基于注意力的SASRec表现优于基于循环神经网络的GRU4Rec，而多兴趣模型的表现优于两者。在图卷积网络的帮助下，MGNM是所比较的多兴趣模型中表现最好的。同时，我们提出的DESMIL模型始终优于所有比较的基线方法，但在Movies数据集上通过NDCG@20评估时除外。

以及电视数据集和CD和黑胶唱片数据集。在Book数据集上，并通过召回率和命中率进行评估，DESMIL的提升十分显著。在实际应用中，召回率通常被认为是最重要的指标，因为面对包含海量候选项目以及数量几乎同等重要但有限的曝光位置时，它最能反映模型性能。这些结果进一步证明了我们提出的DESMIL模型的有效性。此外，与表1和表3中的结果相比，DESMIL在分布外设置下取得的提升远比随机设置下显著。这表明，DESMIL是一个适用于分布外泛化的多兴趣模型，同时在常规数据划分下仍具有出色的性能。

5.6 超参数敏感性（RQ3）

为研究我们提出的模型对超参数的稳定性，我们开展了超参数敏感性研究。在图5和图 6中，我们分别展示了在分布外数据划分和随机数据划分下，去相关重要性系数 λ 和兴趣数量 c的敏感性。图中的结果通过Recall@50指标进行评估。我们可以观察到， c 对DESMIL的性能影响并不大。此外，当 $\lambda = 0.0$时，DESMIL的性能会显著下降。而$\lambda = 0.0$ 表明，不进行兴趣去相关的DESMIL，

这也可以视为消融实验。这说明了兴趣去相关在DESMIL中的重要性。同时，当 $\lambda \in [0.01, 0.1, 1.0]$时，DESMIL的性能保持相对稳定，这表明在实践中我们不需要为超参数调优承担太多负担。在其他实验中，我们简单地将 $\lambda = 1.0$和 $c = 2$ 设为。

5.7 可视化（RQ4 和 RQ5）

在图7中，我们展示了在 Book 数据集上训练 DESMIL 和 ComiRec 时，训练集上的 HSIC 和验证集上的召回率变化情况。DESMIL 和 ComiRec 都采用提前停止，且训练在不同的步骤终止，因此图中曲线的长度有所不同。需要注意的是，DESMIL 在训练阶段通过样本重新加权来优化 HSIC，而图中展示的 HSIC 计算结果未经过加权。与 DESMIL 不同，ComiRec 在训练期间不控制 HSIC（即兴趣之间相关性）的优化。在前 10000 步中，两个模型的 HSIC 和召回率都迅速上升。随后，ComiRec 的 HSIC 继续快速上升，而 DESMIL 的 HSIC 则相对平稳地增长。这使 DESMIL 能够进行更多步的更新，并取得更好的性能。总之，通过最小化基于公式（11）中 HSIC 的加权相关性估计损失，我们可以打破图3中引入的兴趣之间相关性与模型性能之间的权衡关系，并减轻稳定兴趣与噪声兴趣之间可能误导模型学习虚假相关的依赖关系。

此外，在图 8 中，我们以直方图的形式展示了 DESILL 在 Book 数据集上学习到的样本权重概率分布。图中的样本权重主要分布在0.8 至1.0之间，另有一些接近0.0。接近1.0 的值表示样本权重变化较小，而接近0.0 的值则表示主要目标损失函数中的样本权重变化剧烈。这表明，Book 数据集中的大多数样本不需要进行特定的去相关操作，而少部分样本确实被边缘化。

6 结论

本文研究多兴趣模型中的分布外泛化问题，以实现准确且稳定的序列推荐。为此，我们提出了一种新颖的多兴趣推荐模型，称为 DESMIL。DESMIL 使用注意力模块提取多个兴趣，并选择其中最重要的兴趣来进行最终预测。随后，我们引入加权相关性估计损失，以缓解训练集中不同提取兴趣之间的相关性。DESMIL模型能够在序列推荐中学习稳定表示，并生成可泛化至分布外环境的稳定且准确的预测。在分布外和随机设置下进行的大量实验结果有力地表明，我们提出的 DESMIL模型是一种前景良好的序列推荐模型。

参考文献

[1] F. Yu、Q. Liu、S. Wu、L. Wang 和 T. Tan，“用于下一篮子推荐的动态循环模型”，载于国际 *ACM SIGIR* 信息检索研究与发展会议论文集，2016年，第 729–732 页。[2] B. Hidasi、A. Karatzoglou、L. Baltrunas 和 D. Tikk，“基于循环神经网络的会话式推荐”，2016年。[3] J. Tang 和 K. Wang，“通过卷积序列嵌入实现个性化 top-n 序列推荐”，载于*ACM* 国际 *Web* 搜索与数据挖掘会议论文集，2018年，第 565–573 页。[4] Q. Liu、Y. Zeng、R. Mokhosi 和 H. Zhang，“Stamp：面向会话式推荐的短期注意力/记忆优先模型”，载于*ACM SIGKDD* 国际知识发现与数据挖掘会议论文集，2018年，第 1831–1839 页。[5] W.-C. Kang 和 J. McAuley，“自注意力序列推荐”，载于*IEEE* 国际数据挖掘会议，2018年，第 197–206 页。[6] F. Sun、J. Liu、J. Wu、C. Pei、X. Lin、W. Ou 和 P. Jiang，“Bert4rec：基于 Transformer 双向编码器表示的序列推荐”，载于*ACM* 国际信息与知识管理会议论文集，2019年，第 1441–1450 页。[7] C. Li、Z. Liu、M. Wu、Y. Xu、H. Zhao、P. Huang、G. Kang、Q. Chen、W. Li 和 D. L. Lee，“用于天猫推荐的动态路由多兴趣网络”，载于*ACM* 国际信息与知识管理会议论文集，2019年，第 2615–2623 页。[8] Y. Cen、J. Zhang、X. Zou、C. Zhou、H. Yang 和 J. Tang，“用于推荐的可控多兴趣框架”，载于*ACM SIGKDD* 国际知识发现与数据挖掘会议论文集，2020年，第 2942–2951 页。[9] Q. Tan、J. Zhang、J. Yao、N. Liu、J. Zhou、H. Yang 和 X. Hu，“用于序列推荐的稀疏兴趣网络”，载于*ACM* 国际 *Web* 搜索与数据挖掘会议论文集，2021年，第 598–606 页。[10] Y. Tian、J. Chang、Y. Niu、Y. Song 和 C. Li，“当多层次遇上多兴趣：用于序列推荐的多粒度神经模型”，载于国际 *ACM SIGIR* 信息检索研究与发展会议论文集，2022年，第 1632–1641 页。[11] Z. Shen、J. Liu、Y. He、X. Zhang、R. Xu、H. Yu 和 P. Cui，“迈向分布外泛化：综述”，*arXiv* 预印本 *arXiv:2108.13624*，2021年。[12] S. Zhang、D. Yao、Z. Zhao、T.-S. Chua 和 F. Wu，“CauseRec：用于序列推荐的反事实用户序列合成”，载于国际 *ACM SIGIR* 信息检索研究与发展会议论文集，2021年，第 367–377 页。[13] T. Schnabel、A. Swaminathan、A. Singh、N. Chandak 和 T. Joachims，“将推荐视为处理：去偏学习与评估”，载于国际机器学习会议，2016年，第 1670–1679 页。[14] X. Wang、R. Zhang、Y. Sun 和 J. Qi，“针对非随机缺失数据的推荐双重稳健联合学习”，载于国际机器学习会议，2019年，第 6638–6647 页。[15] D. Arbour、D. Dimmery 和 A. Sondhi，“置换加权”，载于国际机器学习会议。PMLR，2021年，第 331–341 页。[16] Z. Wang、S. Shen、Z. Wang、B. Chen、X. Chen 和 J.-R. Wen，“带潜在混杂因素的无偏序列推荐”，载于*ACM Web* 会议论文集，2022年，第 2195–2204 页。[17] Y. Zhang、F. Feng、X. He、T. Wei、C. Song、G. Ling 和 Y. Zhang，“通过因果干预利用推荐中的流行度偏差”，载于国际 *ACM SIGIR* 信息检索研究与发展会议论文集，2021年，第 11–20 页。[18] Z. Wang、J. Zhang、H. Xu、X. Chen、Y. Zhang、W. X. Zhao 和 J.-R. Wen，“反事实数据增强的序列推荐”，载于国际 *ACM SIGIR* 信息检索研究与发展会议论文集，2021年，第 347–356 页。[19] Z. Shen、P. Cui、T. Zhang 和 K. Kunag，“通过样本重加权实现稳定学习”，载于*AAAI* 人工智能会议论文集，2020年，第 5692–5699 页。[20] K. Kuang、P. Cui、S. Athey、R. Xiong 和 B. Li，“跨未知环境的稳定预测”，载于*ACM SIGKDD* 国际知识发现与数据挖掘会议论文集，2018年，第 1617–1626 页。

[21] K. Kuang、R. Xiong、P. Cui、S. Athey 和 B. Li，“在模型设定错误和分布偏移未知的情况下实现稳定预测”，载于 AAAI 人工智能会议论文集，2020年，第 4485–4492 页。[22] K. Kuang、H. Zhang、R. Wu、F. Wu、Y. Zhuang 和 A. Zhang，“跨未知测试数据的平衡子采样稳定预测”，ACM Transactions on Knowledge Discovery from Data (TKDD)，第 16 卷，第 3 期，第 1–21 页，2021年。[23] A. Vaswani、N. Shazeer、N. Parmar、J. Uszkoreit、L. Jones、A. N. Gomez、Ł. Kaiser 和 I. Polosukhin，“注意力机制就是你所需要的一切”，载于《神经信息处理系统进展》，2017年，第 5998–6008 页。[24] A. Gretton、O. Bousquet、A. Smola 和 B. Sch¨olkopf，“使用希尔伯特-施密特范数度量统计依赖性”，载于《学习理论年会》，2005年，第 63–77 页。[25] A. Gretton、K. Fukumizu、C. H. Teo、L. Song、B. Sch¨olkopf、A. J. Smola 等，“独立性的核统计检验”，载于《神经信息处理系统进展》，2007年，第 585–592 页。[26] H. Bahng、S. Chun、S. Yun、J. Choo 和 S. J. Oh，“ 利用有偏表示学习去偏表示 ”，载于《国际机器学习会议》，2020年，第 528–539 页。[27] X. Zhang、P. Cui、R. Xu、L. Zhou、Y. He 和 Z. Shen，“用于分布外泛化的深度稳定学习”，载于《IEEE/CVF 计算机视觉与模式识别会议论文集》，2021年，第 5372–5382 页。[28] S. Fan、X. Wang、C. Shi、P. Cui 和 B. Wang，“在分布外图上泛化图神经网络”，arXiv 预印本 arXiv:2111.10657，2021年。[29] H. Fang、D. Zhang、Y. Shu 和 G. Guo，“序列推荐的深度学习：算法、影响因素与评估”，ACM Transactions on Information Systems (TOIS)，第 39 卷，第 1 期，第 1–42 页，2020年。[30] S. Rendle、C. Freudenthaler 和 L. Schmidt-Thieme，“用于下一篮子推荐的个性化马尔可夫链分解”，载于 ACM Web 会议论文集，2010年，第 811–820 页。[31] R. He 和 J. McAuley，“将相似性模型与马尔可夫链融合用于稀疏序列推荐”，载于 IEEE 国际数据挖掘会议，2016年，第 191–200 页。[32] R. He、W.-C. Kang 和 J. McAuley，“基于翻译的推荐”，载于 ACM 推荐系统会议论文集，2017年，第 161–169 页。[33] B. Hidasi 和 D. Tikk，“面向上下文感知推荐的通用分解框架”，《数据挖掘与知识发现》，第 30 卷，第 2 期，第 342–371 页，2016年。[34] Q. Liu、S. Wu、L. Wang 和 T. Tan，“下一位置预测：结合空间与时间上下文的循环模型”，载于 AAAI 人工智能会议论文集，2016年。[35] Q. Liu、S. Wu、D. Wang、Z. Li 和 L. Wang，“上下文感知序列推荐”，载于 IEEE 国际数据挖掘会议，2016年，第 1053–1058 页。[36] Q. Liu、S. Wu 和 L. Wang，“基于循环对数双线性模型的多行为序列预测”，《IEEE 知识与数据工程汇刊》第 29 卷，第 6 期，第 1254–1267 页，2017年。[37] J. Wang、Q. Liu、Z. Liu 和 S. Wu，“迈向准确且可解释的序列预测：基于 CNN 与注意力机制的特征提取器”，载于 ACM 国际信息与知识管理会议论文集，2019年，第 1703–1712 页。[38] Y. Luo、Q. Liu 和 Z. Liu，“Stan：用于下一位置推荐的时空注意力网络”，载于 ACM Web 会议论文集，2021年，第 2177–2185 页。[39] J. Li、Y. Wang 和 J. McAuley，“面向时间间隔的序列推荐自注意力机制”，载于 ACM 国际 Web 搜索与数据挖掘会议论文集，2020年，第 322–330 页。[40] C. Hsu 和 C.-T. Li，“ Retagnn：用于整体序列推荐的关系时序注意力图神经网络”，载于 ACM Web 会议论文集，2021年，第 2968–2979 页。[41] Z. Fan、Z. Liu、Y. Wang、A. Wang、Z. Nazari、L. Zheng、H. Peng 和 P. S. Yu，“通过随机自注意力实现序列推荐”，载于 ACM Web 会议论文集，2022年，第 2036–2047 页。[42] G. Zhou、X. Zhu、C. Song、Y. Fan、H. Zhu、X. Ma、Y. Yan、J. Jin、H. Li 和 K. Gai，“用于点击率预测的深度兴趣网络”，载于 ACM SIGKDD 国际知识发现与数据挖掘会议论文集，2018年，第 1059–1068 页。[43] G. Zhou、N. Mou、Y. Fan、Q. Pi、W. Bian、C. Zhou、X. Zhu 和 K. Gai，“用于点击率预测的深度兴趣演化网络”，载于 AAAI 人工智能会议论文集，2019年，第 5941–5948 页。

[44] K. Zhou、H. Wang、W. X. Zhao、Y. Zhu、S. Wang、F. Zhang、Z. Wang 和 J.-R. Wen，《S3-rec：通过互信息最大化进行序列推荐的自监督学习》，载于 *ACM* 信息与知识管理国际会议论文集，2020年，第1893–1902页。[45] X. Xie、F. Sun、Z. Liu、S. Wu、J. Gao、B. Ding 和 B. Cui，《序列推荐的对比学习》，*arXiv* 预印本 *arXiv:2010.14395*，2020年。[46] Z. Liu、Y. Chen、J. Li、P. S. Yu、J. McAuley 和 C. Xiong，《通过鲁棒增强进行对比式自监督序列推荐》，*arXiv* 预印本 *arXiv:2108.06479*，2021年。[47] Y. Chen、Z. Liu、J. Li、J. McAuley 和 C. Xiong，《序列推荐的意图对比学习》，载于 *ACM Web* 会议论文集，2022年，第2172–2182页。[48] Q. Cui、S. Wu、Q. Liu、W. Zhong 和 L. Wang，《Mv-rnn：用于序列推荐的多视图循环神经网络》，*IEEE* 知识与数据工程汇刊，第32卷第2期，第317–331页，2018年。[49] C. Liu、X. Li、G. Cai、Z. Dong、H. Zhu 和 L. Shang，《用于序列推荐中侧信息融合的非侵入式自注意力机制》，载于 *AAAI* 人工智能会议论文集，2021年，第4249–4256页。[50] Y. Xie、P. Zhou 和 S. Kim，《用于序列推荐的解耦侧信息融合》，载于国际 *ACM SIGIR* 信息检索研究与发展会议论文集，2022年，第1611–1621页。[51] S. Mu、Y. Li、W. X. Zhao、J. Wang、B. Ding 和 J.-R. Wen，《通过反事实生成器缓解知识感知推荐中的虚假相关》，载于国际 *ACM SIGIR* 信息检索研究与发展会议论文集，2022年，第1401–1411页。[52] W. Wang、X. Lin、F. Feng、X. He、M. Lin 和 T.-S. Chua，《分布外推荐的因果表征学习》，载于 *ACM Web* 会议论文集，2022年，第3562–3571页。[53] H. Wang、T.-W. Chang、T. Liu、J. Huang、Z. Chen、C. Yu、R. Li 和 W. Chu，《Escm2：用于点击后转化率估计的全空间反事实多任务模型》，载于 第*45*届国际 *ACM SIGIR* 信息检索研究与发展会议论文集，2022年，第363–372页。[54] W. Wang、F. Feng、X. He、H. Zhang 和 T.-S. Chua，《点击可能具有欺骗性：缓解标题党问题的反事实推荐》，载于 国际 *ACM SIGIR* 信息检索研究与发展会议论文集，2021年，第1288–1297页。[55] S. Guo、L. Zou、Y. Liu、W. Ye、S. Cheng、S. Wang、H. Chen、D. Yin 和 Y. Chang，《用于去偏点击后转化率估计的增强双重稳健学习》，载于 第*44*届国际 *ACM SIGIR* 信息检索研究与发展会议论文集，2021年，第275–284页。[56] T. Wei、F. Feng、J. Chen、Z. Wu、J. Yi 和 X. He，《用于消除推荐系统流行度偏差的模型无关反事实推理》，载于 *ACM SIGKDD* 知识发现与数据挖掘国际会议论文集，2021年，第1791–1800页。[57] K. Damak、S. Khenissi 和 O. Nasraoui，《利用双向 Transformer 对序列推荐中的完形填空任务进行去偏》，载于 *ACM SIGKDD* 知识发现与数据挖掘国际会议论文集，2022年，第273–282页。[58] C. Xu、J. Xu、X. Chen、Z. Dong 和 J.-R. Wen，《序列推荐中的双重增强倾向得分估计》，载于*ACM* 信息与知识管理国际会议论文集，2022年，第2260–2269页。[59] M. Yang、Q. Dai、Z. Dong、X. Chen、X. He 和 J. Wang，《基于反事实用户偏好模拟的 Top-n 推荐》，载于 *ACM* 信息与知识管理国际会议论文集，2021年，第2342–2351页。[60] N. Liu、Q. Tan、Y. Li、H. Yang、J. Zhou 和 X. Hu，《单个向量足够吗？探索网络嵌入中的节点多义性》，载于 *ACM SIGKDD* 知识发现与数据挖掘国际会议论文集，2019年，第932–940页。[61] W. Chen、P. Ren、F. Cai、F. Sun 和 M. de Rijke，《通过意图感知的多样化改进端到端序列推荐》，载于 *ACM* 信息与知识管理国际会议论文集，2020年，第175–184页。[62] J. Ma、C. Zhou、P. Cui、H. Yang 和 W. Zhu，《学习解耦表征用于推荐》，2020年。[63] S. Sabour、N. Frosst 和 G. E. Hinton，《胶囊之间的动态路由》，*arXiv* 预印本 *arXiv:1710.09829*，2017年。

[64] G. E. Hinton、S. Sabour 和 N. Frosst，《采用 EM 路由的矩阵胶囊》，载于 国际学习表征会议，2018年。[65] G. E. Hinton、A. Krizhevsky 和 S. D. Wang，《变换自编码器》，载于 国际人工神经网络会议，2011年，第44–51页。[66] Z. Chai、Z. Chen、C. Li、R. Xiao、H. Li、J. Wu、J. Chen 和 H. Tang，《推荐系统中的用户感知多兴趣学习与候选匹配》，载于 国际 *ACM SIGIR* 信息检索研究与发展会议论文集，2022年，第1326–1335页。[67] S. Fan、X. Wang、C. Shi、K. Kuang、N. Liu 和 B. Wang，《具有无关标签选择偏差的去偏图神经网络》，*IEEE* 神经网络与学习系统汇刊，2022年。[68] H. Li、X. Wang、Z. Zhang 和 W. Zhu，《OOD-GNN：分布外广义图神经网络》，*IEEE* 知识与数据工程汇刊，2022年。[69] Y. Luo、Z. Liu 和 Q. Liu，《电子健康记录上的深度稳定表征学习》，载于 *IEEE* 国际数据挖掘会议，2022年。[70] R. Xu、P. Cui、Z. Shen、X. Zhang 和 T. Zhang，《稳定学习为何有效？协变量偏移泛化理论》，*arXiv* 预印本*arXiv:2111.02355*，2021年。[71] J. McAuley、C. Targett、Q.Shi和 A.Van Den Hengel，“基于风格和替代品的图像推荐”，载于 国际*ACM SIGIR* 信息检索研究与开发会议论文集，2015年，第 43–52 页。[72] R.He 和 J.McAuley，“潮起潮落：使用单类协同过滤对时尚趋势的视觉演变进行建模”，载于 *ACM Web*会议论文集，2016年，第 507–517页。[73] P. Covington、J. Adams 和 E.Sargin，“用于 YouTube推荐的深度神经网络”，载于 *ACM* 推荐系统会议论文集，2016年，第191–198 页。[74] S. Jean、K. Cho、R.Memisevic和 Y. Bengio，“关于在神经机器翻译中使用超大目标词汇表”，*arXiv*预印本*arXiv:1412.2007*，2014年。[75] X. Glorot和 Y. Bengio，“理解训练深度前馈神经网络的困难”，载于 国际人工智能与统计学会议论文集，2010年，第 249–256 页。[76] J.Ni、J.Li 和 J. McAuley，“使用远程标注评论和细粒度方面为推荐提供依据”，载于 自然语言处理实证方法会议论文集，2019年，第 188–197 页。