arXiv:2304.04218v1 [cs.IR] 9 Apr 2023

面向非重叠跨域序列推荐的自动提示

Lei Guo ，Chunxiao Wang，Xinhua Wang，Lei Zhu，尹洪志，*IEEE* 高级会员

摘要—近年来，跨域推荐（CR）通过利用不同领域的信息缓解推荐系统中的数据稀疏问题，得到了广泛研究。本文聚焦于更一般的非重叠跨域序列推荐（NCSR）场景。NCSR 面临诸多挑战，因为不同领域之间不存在重叠实体（例如用户和物品），而且只有用户的隐式反馈，没有内容信息。以往的 CR 方法无法很好地解决 NCSR，原因在于：（1）它们要么需要额外的内容来对齐领域，要么需要显式的领域对齐约束，以利用领域不变特征缩小领域差异；（2）它们更关注用户的显式反馈（即用户的评分数据），无法很好地捕捉用户的序列交互模式；（3）它们通常执行单目标跨域推荐任务，很少研究双目标任务。针对上述挑战，我们提出了基于提示学习的跨域推荐器（PLCR），这是一种面向 NCSR 任务的自动提示推荐框架。具体而言，为应对挑战（1），PLCR 通过提示学习组件学习领域不变表示和领域特定表示，并舍弃领域对齐约束。针对挑战（2）和（3），PLCR 引入预训练序列编码器来学习用户的序列交互模式，并通过带有分离约束的双重学习目标，增强两个领域中的推荐效果。我们在亚马逊的两个子集合上进行的实证研究表明，与一些相关的最先进方法相比，PLCR 表现更优。

索引词—提示学习、领域自适应、序列推荐、跨域推荐

1 引言

Due 跨域信息对于缓解推荐系统中的稀疏性问题具有显著效果 [1], [2], [3], 旨在提升跨域推荐（CR）任务正受到越来越多的关注。此外，由于用户交互之间存在稳固的时间关系 [4], [5], 能够对用户序列兴趣进行建模的跨域序列推荐（CSR）任务也日益受到关注。这些方法的一个典型假设是，不同领域之间存在全部或部分重叠实体 [6], [7], [8], [9], 借助这些实体，它们可以更轻松地在领域之间进行知识迁移。

本文研究一种特别具有挑战性的场景下的跨域序列推荐：非重叠跨域序列推荐（NCSR）。在该场景中，不同域之间的用户和物品完全不相连，且只能观测到用户的正向交互（没有可用的额外内容信息）。我们考虑非重叠这一特性，是因为它在实践中十分常见。例如，电影观看服务与图书阅读服务中的物品完全不同；此外，出于业务隐私政策的限制，让不同平台/系统拥有重叠用户并不现实。不存在重叠的】【。

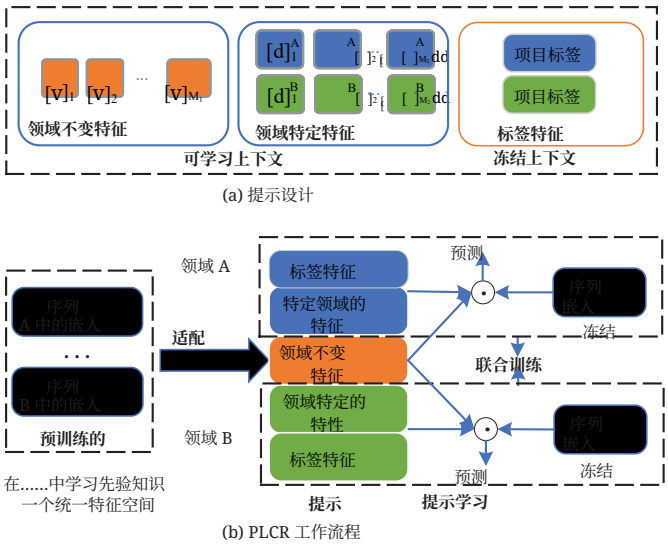


图 1. 我们的提示设计及 PLCR的工作流程：首先通过在两个领域上进行联合预训练，在统一特征空间下对先验知识进行建模；然后通过提示学习将先验知识适配到特定领域。所学习的提示在源领域和目标领域内的各个序列之间共享，表示用户与物品之间的共同交互模式。这些提示也可以被解释为用户的簇级兴趣。我们通过将先验知识映射到统一特征空间，并在不同领域之间共享提示的领域不变上下文，在无需领域对齐的情况下实现知识迁移。

实体和额外的辅助信息使得跨域传递有用信息更加困难，因为它们之间没有直接连接。

以往关于非重叠跨域推荐（NCR）的研究

• *L. Guo*、*C. Wang*、*X. Wang* 和 *L. Zhu* 就职于中国济南 *250014* 的山东师范大学计算机科学与技术学院。电子邮箱：*leiguo.cs@gmail.com*、*wangchunxiao0217@163.com*、*wangxin- hua@sdnu.edu.cn*、*leizhu0608@gmail.com*

• *H. Yin* 就职于澳大利亚昆士兰州圣卢西亚 *4072* 的昆士兰大学信息技术与电气工程学院。电子邮箱：*h.yin1@uq.edu.au* 收稿日期：*2023*年 *XX XX*；修订日期：*2023*年 *XX XX*。（通讯作者：尹洪志。）

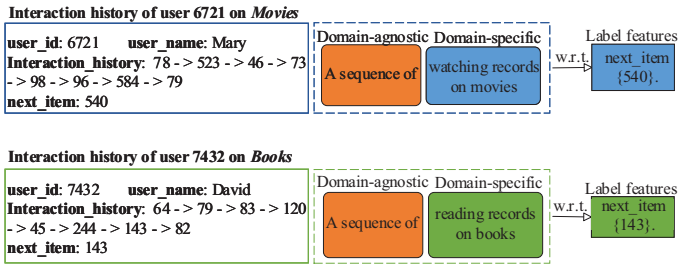


图2. 我们设计的提示示例。领域无关上下文表示独立于领域的一般特征（由两个领域共享），领域特定上下文表示与特定领域相关的特征（由同一领域内的用户共享）。

主要关注从评分数据中提取领域信息，而用户序列数据上的表现则鲜少得到探索。此外，当前的 NCR 解决方案主要致力于学习跨领域的不变特征，以便在领域之间共享领域信息，从而提升各领域的推荐效果 [10], [11], [12], [13], [14]。这类方法的一种常见做法是采用对抗训练 [12], [15], [16], ，通过混淆领域判别器来缩小源领域与目标领域之间的差距。然而，由于语义信息与领域信息相互纠缠，通过领域对齐来缩小差异可能会导致部分语义信息（即序列所包含的用户偏好／意图）丢失。当数据分布具有复杂的流形结构时，这一问题可能会更加严重。为解决这一问题，近期方法主张保留语义信息，以维持推荐器的预测能力 [17]。然而，领域对齐与保留语义特征这两个目标可能相互对立，因此这些方法往往难以在二者之间取得微妙的平衡。另一种解决这一问题的方法是学习解耦的语义表示和领域表示 [18], [19], ，并舍弃领域对齐约束。但现有研究要么忽视了非重叠特性 [18] ，要么需要额外的内容来连接不同领域 [19]。此外，现有关于 NCR 的研究主要聚焦于单目标任务，即将领域知识从稠密源领域迁移到稀疏目标领域。相比之下，旨在提升两个领域推荐效果的双目标任务鲜少得到研究。

为应对上述挑战，在本研究中，我们着眼于 NCSR，并提出一种基于提示学习的跨域推荐器（PLCR），通过借助自动化提示工程范式的优势来实现这一目标 [20]。PLCR 的工作流程如图 1 所示：首先将各领域中的先验知识嵌入预训练模型，然后通过在各领域间共享提示，动态地将模型适配到特定领域，从而在彼此不连通的领域中进行推荐。与现有工作相比，我们的方法利用预训练序列模型进行提示优化与适配，无需满足领域对齐约束，也无需额外内容，且只需优化少量参数。具体而言，我们将每个提示设计为三个组成部分（图 1 展示了我们的提示设计）：领域无关上下文、领域特定上下文和标签上下文。其中，领域无关上下文表示领域不变的语义特征，并在所有具有相同标签的序列之间共享。领域特定上下文表示各领域间的共通信息。项目标签指真实物品的特征，在优化过程中将保持冻结。我们设计的提示示例如图 2 所示。

随后，为了进行双目标跨域推荐，并确保学到的语义表征和领域表征在这样的连续特征空间中实现解耦（我们不使用离散提示，因为无法保证它们对下游任务而言是最优的），我们采用分离约束进行优化（如图 3 所示）。具体而言，我们基于复合提示设计了两个优化目标，通过在领域之间共享领域无关特征，并利用复合学习目标进行双目标跨域推荐。在我们的学习范式中，领域无关特征在不同领域之间共享，旨在帮助重构用户在两个领域中的共同兴趣；而领域特定特征则用于建模与领域特定特征解耦的领域无关方面。

我们将主要贡献总结如下：

- 我们在一个更通用但更具挑战性的场景——NCSR 中研究 CSR。为克服以往研究的局限，我们提出一种自动化提示范式，对不重叠特性进行建模，从而探索 NCSR。
- 我们设计了一种自动化提示工程范式，使预训练序列模型适应特定领域。借助共享的提示上下文，我们能够在不相交领域之间迁移信息。
- 我们提出了一种分离约束，以促进学习到的领域不变特征和领域特定特征分别捕获领域的不同方面，从而支持双目标跨域推荐。
- 我们在亚马逊的两个子集合上开展了大量实验，以评估我们的方法。实验结果表明，与当前最先进的基线方法相比，我们提出的方法具有优势。

2 相关工作

在本节中，我们将重叠/非重叠实体的跨域推荐和基于提示学习的推荐作为相关工作。

2.1 基于重叠实体的跨域推荐

现有关于跨领域迁移领域知识的研究，主要致力于通过重叠用户、物品或其中一部分来开发领域对齐方法。在这些方法中，只有少数倾向于假设不同领域之间的用户和物品完全重叠，并通过利用用户对同一物品集合的共同兴趣来提升推荐效果 [21], [22], [23],[24]。例如，Pan 等人 [22] 旨在减少数据

协同过滤领域中的稀疏性问题，并通过提出一种集体分解方法来解决该问题，在这种方法中共同构建了一个共享潜在空间。为了增强跨域推荐，Zhu 等人 [23] 首先通过分离异构图来学习用户和物品的嵌入，然后设计一个逐元素网络，以连接不同领域间共享实体的嵌入。由于假设两个领域拥有完全相同的用户和物品过于理想化，近期研究开始关注仅有用户重叠的场景 [6], [7], [9], [25], [26], [27], [28], [29], [30], [31], [32], [33], [34]。例如，Guo 等人 [6]通过提出一种基于网络的解决方案，研究了具有重叠用户的序列推荐任务；在该方案中，他们利用图卷积网络，将用户在另一领域的偏好与用户表征相结合，从而增强用户的表征。Li等人 [25] 通过研究用户在两个领域中的兴趣，提出了一种双向迁移跨域推荐器，以开展跨域推荐。考虑到用户对齐所带来的隐私问题，Gao 等人 [14] 仅将重叠物品视为连接不同领域的桥梁，并利用神经网络学习高维表征的能力，从迁移的物品嵌入中提取有用信息。

然而，由于上述方法需要重叠实体来连接各个域，因此当实体完全不重叠时，其应用可能会受到限制。为此，我们聚焦于非重叠跨域推荐任务，并提出一种基于提示学习的方法来解决知识迁移问题。

2.2 基于非重叠实体的跨域推荐

与重叠或部分重叠的方法相比，非重叠跨域推荐任务更具挑战性，因为领域之间缺少直接连接。根据不同的推荐目标，近期该类别的工作可分为单目标、双目标或多目标，以及一对多跨域推荐方法。单目标跨域推荐任务倾向于利用源领域中的有用知识来增强目标领域中的推荐，旨在缓解目标领域中的冷启动和稀疏性问题 [10], [11], [12], [13], [15], [35], [36]。例如，Liu等人 [10] 通过提出一种基于归因对齐的协同过滤方法，研究了基于评论的非重叠跨域推荐任务。但他们的工作需要额外的评论和归因信息，而这些信息在现实场景中可能无法获得；为了对齐领域，这限制了其在真实系统中的应用。双目标或多目标跨域推荐任务倾向于开展双向或多向跨域推荐，使两个或多个领域能够从知识交换中受益 [16], [37], [38]。例如，Zhang 等人 [16] 在双重对抗学习框架下，通过利用领域判别器学习共享编码器，对齐领域之间用户和项目的特征空间。Li 等人 [38] 通过提出一种评分矩阵生成模型，研究了多目标跨域推荐任务，其中一个隐式的簇级建立评分矩阵以寻找多个领域之间的相关性。针对一对多跨域推荐任务的研究主要聚焦于将有助益的领域信息从稠密源领域迁移到新的稀疏目标领域 [11], [35], [39], [40]。例如，Krishnan 等人 [39] 通过在稠密领域和稀疏领域之间共享领域无关组件，研究了非重叠跨域推荐任务。

但现有的不相交领域研究主要聚焦于单目标跨域推荐任务，只有少数研究考虑同时增强两个领域中的推荐效果。此外，上述研究主要从评分数据中挖掘领域知识，其在序列数据上的表现尚未得到验证。更重要的是，现有研究均未探讨如何利用提示学习技术进行知识迁移，而这正是本文的主要任务。

2.3 基于提示学习的推荐

提示是一种向输入和预训练语言模型 [41] 前置指令、旨在提示下游任务的方法。由于其在调优预训练模型方面的有效性，近期研究已成功将其应用于自然语言处理任务 [41], [42], [43], [44], [45], [46], ，其中一些研究还探讨了将其应用于推荐任务 [47], [48], [49], [50], [51], [52], [53],[54]。例如，Li 等人 [47] 将提示学习引入可解释推荐任务。他们倾向于通过弥合连续提示与预训练模型之间的差距，提升推荐系统的解释生成性能。为了让用户能够灵活选择敏感属性，Wu等人 [51] 将自然语言处理中的提示技术引入推荐系统，设计了一种基于提示的公平性感知推荐系统。Geng 等人 [48] 将推荐视为语言处理，研究任务之间的知识迁移问题，并提出了一种名为 P5的统一且灵活的文本到文本范式，用于推荐。但他们的工作需要使用相同的数据集进行训练和测试，这与我们的工作不同，因为我们专注于为完全不重叠的数据集学习模型。

然而，现有利用提示技术改进推荐的研究仍处于起步阶段，且没有研究考虑跨不相交领域的信息传递问题。

3 方法论

本节首先详细介绍 NCSR 任务的定义，然后展示如何实现 PLCR，以基于提示学习开展跨域推荐。

3.1 预备知识

假设我们有两个领域 A 和B，并且可以获取用户在两个领域中的序列行为。NCSR的目标是基于用户的历史交互，推荐用户将在源领域或目标领域中交互的下一个物品。但不同于传统 CSR，NCSR 更关注非重叠场景，即两个领域中的用户和物品完全不相交。

由于缺少可直接用于领域对齐的桥接实体，NCSR 是一项更具挑战性的任务。为应对这一挑战，我们通过提示学习技术为NCSR 带来了新的思路。在我们的设定中，提示是一种向预训练序列和物品编码器添加的前置指令。它们旨在提示这些预训练模型，引导两个领域中的推荐。我们倾向于自动寻找最优提示，以提供准确的指导，而不是利用人工设计的提示。

更正式地说，设 $\mathcal{V}_A = \{A_1, A_2, ..., A_m, ..., A_M\}$ 为领域 A 中的物品集合，$\mathcal{V}_B = \{B_1, B_2, ..., B_n, ..., B_N\}$ 为领域 B 中的物品集合（假设 A 和 B 中的物品互不重叠）。然后，我们可以从用户与这些物品的交互日志中，分别获得他们在领域 A 和领域 B 中的序列行为，记为 $(A_1, A_2, ..., A_m, ...)$ 和 $(B_1, B_2, ..., B_n, ...)$，其中 $A_m \in \mathcal{V}_A$ 和 $B_n \in \mathcal{V}_B$ 分别是在 A 和 B 中发生过交互的物品。由于领域间具有非重叠特性，两个领域的用户集合和物品集合完全不相交。也就是说，我们无法获取同一用户在两个领域中的序列行为，因而无法直接利用她在一个领域中的交互来增强她在另一个领域中的兴趣建模。因此，NCSR 的目标可定义为构建一个映射函数 $f(\S)$，通过探索非重叠跨域序列数据，预测物品集合$\mathcal{V}_A$ (或 $\mathcal{V}_B$)上的概率分布，从而提升两个领域中的推荐效果。

3.2 PLCR 概述

在这项工作中，我们设计了 PLCR，借助提示学习的力量来解决 NCSR 中的领域适配问题。

动机。 由于不同领域之间缺乏共同实体，因此无法通过对齐两个领域来实现跨域推荐。以往对齐两个领域的一类典型方法往往会施加对抗训练约束，但这可能会导致领域内部领域无关特征结构发生扭曲。这种结构可视为一种与特定领域无关的语义相关特征。尽管已有研究尝试对其加以保留，但仍难以平衡语义信息保留与领域对齐这两个目标。为解决这一问题，我们提出通过设计一种提示学习范式，学习解耦的领域无关表示和领域特定表示，并舍弃领域对齐。本文的主要任务是将领域信息嵌入预训练模型，并通过学习共享提示对其进行动态适配，以增强跨域推荐。

PLCR 的整体系统架构如图 3 所示，主要由三个部分组成：预训练的会话-物品编码器、提示学习和分离约束。1）会话-物品编码器是本方法所基于的预训练序列与物品编码模型。具体而言，我们引入[55] 中的 Transformer 模块，在统一特征空间中为两个领域的会话和物品构建编码器。也就是说，我们使用两个领域的数据同时对编码器进行预训练。此外，在进行提示优化时，所有预训练编码器都保持固定（关于这些编码器预训练的具体细节见第 3.3 节）。2）提示学习组件旨在通过在连续特征空间中学习共享提示，在不同领域间迁移领域知识，从而增强跨域推荐。为捕捉领域信息的不同方面，我们利用领域特定上下文来建模独特的领域特征，并利用领域不变上下文来学习领域间的共有特征（设计详情见第 3.4 节）。3）为确保学到的提示上下文彼此解耦，我们设计了一种分离约束，在双目标学习方案中让不同领域共享领域不变上下文。通过这种方式，领域不变上下文和领域特定上下文能够建模领域的不同方面，因为它们具有不同的优化目标（详情见第 3.5 节）。

3.3 序列和物品编码器预训练

我们采用 [55]，中的自注意力块，即基于自注意力的序列推荐模型（SASRec），作为解决方案的骨干网络。该模型专为序列推荐而设计 [56]，能够从用户过去的所有行为中提取上下文信息。SASRec 将用户的交互序列 $\mathcal{S}_u^A = (A_{u,1}, A_{u,2}, ..., A_{u,t-1})$ 作为输入（以领域 A 为例），并通过考察当前序列中的前 $t-1$ 个物品，预测时间步 t 的下一个物品。SASRec 模型由一个嵌入层、多个自注意力块和一个预测层组成，其中嵌入层对给定序列中的物品及其位置进行编码。自注意力块通过从所有先前交互过的物品中分层提取高级特征，对给定序列进行建模。预测层则根据学习到的物品嵌入和序列嵌入预测下一个物品。我们分别将自注意力块和嵌入层作为序列编码器和物品编码器进行预训练，以帮助我们学习解耦的领域特定表示和领域通用表示。

为了将领域信息嵌入统一特征空间，我们通过联合训练对 SASRec 进行预训练，即采用合并数据的方法训练同一个模型。具体而言，我们通过优化 SASRec，使其对齐为序列和物品学习到的嵌入空间，并将其学习目标定义为二元交叉熵损失 [55]:

$$-\sum_{\mathcal{S}_u \in \mathcal{S}} \sum_{t \in [1,2,...,l_n]} \left[\log(\sigma(\hat{y}_{o_t,t})) + \sum_{j \notin \mathcal{S}_u} \log(1 - \sigma(\hat{y}_{j,t})) \right], \tag{1}$$

其中，$\mathcal{S}_u \in \mathcal{S}$ 是领域 A 或 B 中的用户序列，l_n 是 $\mathcal{S}_u$的长度，$\hat{}y_{o_t,t}$ 是时间步 t 对预期物品 o_t 的预测概率。j 是在每个时间步为每个序列生成的负样本。

由于 SASRec 的核心组件（即自注意力模块）可以通过并行训练加速，其速度比基于 RNN/CNN 的替代方案快一个数量级。也就是说，SASRec 可以扩展到大规模训练数据。然而，由于非重叠特性

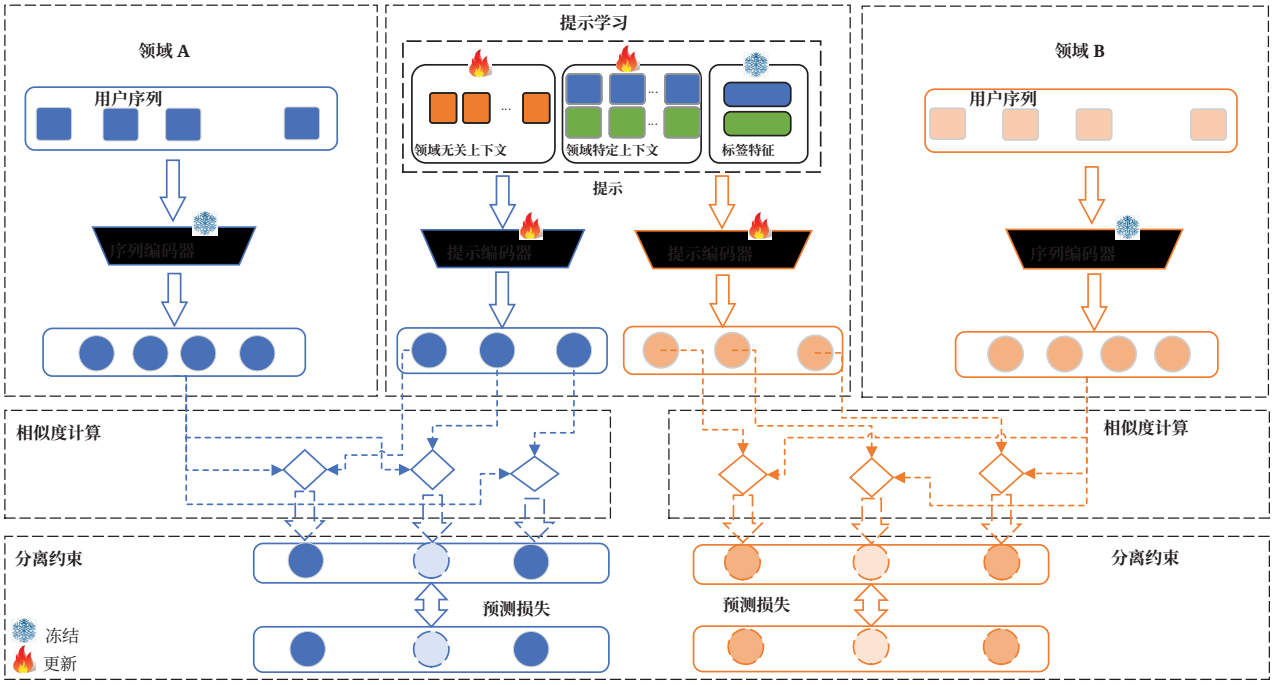


图 3. PLCR 的系统架构，由预训练的序列和物品编码器、提示优化模块以及分离约束组件组成。序列和物品编码器在统一特征空间中进行预训练。提示学习期间，仅更新提示编码器和提示，而预训练模型保持固定。

由于NCSR中缺乏能够连接两个领域的共同实体，SASRec无法直接应用于NCSR，这使我们无法调整跨领域的预嵌入领域知识。

3.4 通过提示优化实现领域适配

将一个领域的领域知识适配到另一个领域的一种典型解决方案，是学习领域不变特征，借助这些特征，推荐器可以进一步进行跨领域推荐。在以往的研究中，对抗训练是一种常用方法，它可以通过利用领域对齐减少目标领域与源领域之间的差异，从而生成领域无关特征。然而，由于这两个目标可能相互对抗，这些方法通常需要在二者之间进行权衡。为克服这一挑战，我们转向提示学习范式，该范式倾向于通过学习跨领域的共享提示来适配预嵌入的领域知识。

3.4.1 提示的设计

如图 1 所示，我们的提示由三个上下文组成：领域无关上下文、领域特定上下文，以及真实物品的标签特征。为避免手动进行提示调优，我们通过自动提示工程，在连续特征空间中对这些上下文进行建模。在提示优化过程中，仅更新提示中的参数，预训练模型保持固定。具体而言，我们使用 $[\boldsymbol{v}]_{m_1}$, $m_1 \in \{1, 2, ..., M_1\}$ 表示领域无关上下文中的词元嵌入 $\boldsymbol{t}_k^A$（以领域 A 为例）。其定义如下：

$$\boldsymbol{t}_k^A = [\boldsymbol{v}]_1[\boldsymbol{v}]_2...[\boldsymbol{v}]_{M_1}[\boldsymbol{Item}]_k^A, \tag{2}$$

其中，$[\boldsymbol{v}]_{m_1}$ 是领域A中第 m_1个上下文词元的向量，M_1 是上下文词元的数量，$\boldsymbol{t}_k^A$是项目 k的领域无关上下文。$[\boldsymbol{Item}]_k^A$是项目 k的嵌入，该嵌入通过骨干网络（即SASRec模型）进行预训练，并将在提示学习期间被冻结。领域无关上下文中的词元嵌入$[\boldsymbol{v}]_{m_1}$ 由两个领域中的所有项目共享，旨在建模与特定领域无关的不变信息，例如用户在不同领域中的共同兴趣。领域 B 中的领域无关上下文$\boldsymbol{t}_k^B$ 可以类似地定义为：

$$\boldsymbol{t}_k^B = [\boldsymbol{v}]_1[\boldsymbol{v}]_2...[\boldsymbol{v}]_{M_1}[\boldsymbol{Item}]_k^B. \tag{3}$$

然而，由于上述词元嵌入往往在不同领域之间共享，因此无法处理领域之间的分布偏移。为了解决这一问题，我们进一步设计了一个领域特定上下文，以建模每个领域中的独特特征，并使用 $[\boldsymbol{d}]_{m_2}^A, \{m_2 \in 1, 2, ..., M_2\}$ 来表示其中的词元嵌入。随后，领域 A 中的提示可重新定义为：

$$\boldsymbol{t}_k^A = [\boldsymbol{v}]_1[\boldsymbol{v}]_2...[\boldsymbol{v}]_{M_1}[\boldsymbol{d}]_1^A[\boldsymbol{d}]_2^A...[\boldsymbol{d}]_{M_2}^A[\boldsymbol{Item}]_k^A, \tag{4}$$

其中，M_2 是领域特定词元的数量，$[\boldsymbol{d}]_{m_2}^A \in \mathbb{R}^d$ 是第 m_2个上下文词元的向量，并将在提示学习过程中进行优化。$[\boldsymbol{v}]_{m_1}$ 和$[\boldsymbol{d}]_{m_2}^A$ 的维度与预训练的序列和物品编码器中的嵌入维度完全相同。领域特定上下文中的词元由所有物品共享，但针对每个领域进行了专门设计。通过这种方式，我们可以对领域偏移进行建模，并捕捉用户在各个领域中的独特兴趣。

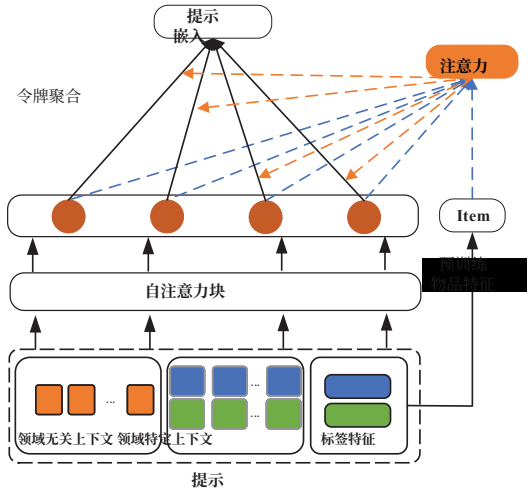


图 4. 提示编码器的设计，由自注意力块和令牌聚合网络组成。

除了将标签特征放在提示词末尾，我们还可以将其放在中间或前面（在领域 B 中也可以实现类似的定义）：

$$\boldsymbol{t}_k^A = [\boldsymbol{v}]_1[\boldsymbol{v}]_2 ... [\boldsymbol{v}]_{M_1}[\boldsymbol{Item}]_k^A[\boldsymbol{d}]_1^A[\boldsymbol{d}]_2^A ... [\boldsymbol{d}]_{M_2}^A, \quad (5)$$

$$\boldsymbol{t}_k^A = [\boldsymbol{Item}]_k^A[\boldsymbol{v}]_1[\boldsymbol{v}]_2 ... [\boldsymbol{v}]_{M_1}[\boldsymbol{d}]_1^A[\boldsymbol{d}]_2^A ... [\boldsymbol{d}]_{M_2}^A. \quad (6)$$

通过这种方式，我们可以让提示既能填充后面的单元格，也能提前截断句子，从而提高提示学习的灵活性。在实验中，我们将其作为一个超参数，并在第 6.2 节报告结果。

3.4.2 提示编码器

为了为提示生成高维特征，我们进一步将其传递给提示编码器 $g(\cdot)$，该编码器由多个自注意力块和一个令牌聚合网络组成，用于注意力聚合与目标项目相关的上下文令牌（$g(\cdot)$ 的架构如图 4 所示）。与 SASRec [55], 类似，我们通过从所有上下文令牌中提取高级信息来建模给定的提示 $\boldsymbol{t}_k^A$（头数和块数作为超参数），并输出 $\boldsymbol{t}_k^A$ 中每个上下文词的表示（以领域 A 为例）。

假设自注意力层的输出表示为：

$$\boldsymbol{s}_k^A = \text{Att}(\boldsymbol{t}_k^A W^Q, \boldsymbol{t}_k^A W^K, \boldsymbol{t}_k^A W^V), \quad (7)$$

其中，Att 是如 [56], $W^Q, W^K, W^V \in \mathbb{R}^{d\times d}$ 中所定义的缩放点积注意力，它们是投影矩阵。然后，为了赋予提取过程非线性，我们进一步对 $\boldsymbol{s}_k^A$ 应用逐点双层前馈神经网络：

$$\boldsymbol{f}_k^A = \text{ReLU}(\boldsymbol{s}_k^A \boldsymbol{W}^{(1)} + \boldsymbol{b}^{(1)})\boldsymbol{W}^{(2)} + \boldsymbol{b}^{(2)}, \quad (8)$$

其中，$\boldsymbol{b}^{(1)}$，$\boldsymbol{b}^{(2)}$ 是 d维向量，$\boldsymbol{W}^{(1)}$，$\boldsymbol{W}$是 $d\times d$矩阵。然后，我们对每个块应用层归一化操作，并将$\boldsymbol{t}_k^A$的自注意力块的最终输出记为 $\boldsymbol{x}_k^A$。

令牌聚合。为了获取序列级别的提示特征，我们进一步通过设计一种注意力机制来聚合 $\boldsymbol{x}_k^A$中的令牌，并以预训练的标签特征 $\boldsymbol{Item}_k^A$作为引导信号：

$$\boldsymbol{z}_k^A = Aggre(\left\{\boldsymbol{x}_{k,i}^A, \forall i \in \mathcal{C}(k)\right\}) = \sum_{i\in\mathcal{C}(k)} \gamma_{k,i}\boldsymbol{x}_{k,i}^A, \quad (9)$$

其中，$\mathcal{C}(k)$ 是 $\boldsymbol{x}_k^A$ 中的词元集合，$\gamma_{k,i}$ 表示与标签特征相关的第 i 个词元的必要性，其由两层神经网络参数化：

$$\gamma_{k,i}^* = \boldsymbol{w}_2^T \cdot \sigma(\boldsymbol{W}_1 \cdot [\boldsymbol{Item}_k^A \oplus \boldsymbol{x}_{k,i}^A] + \boldsymbol{b}_1) + \boldsymbol{b}_2 \quad (10)$$

$$\gamma_{k,i} = \frac{exp(\gamma_{k,i}^*)}{\sum_{i\in\mathcal{C}(k)} exp(\gamma_{k,i}^*)} \quad (11)$$

其中 $\sigma(\cdot)$ 是非线性激活函数，$\boldsymbol{W}$ 和 $\boldsymbol{b}$是权重和偏置参数，$\oplus$ 是拼接操作，$\boldsymbol{Item}_k^A$ 是项目A_k的预训练标签特征，并将在优化过程中保持冻结。

3.4.3 提示优化

给定源域和目标域中的训练样本，我们可以得到向给定序列 $\mathcal{S}_i^A$推荐物品 A_k 的概率（以域 A 为例）：

$$p(\hat{y}_i^A = A_k|\mathcal{S}_i^A) = \frac{\exp\left(\langle g(\boldsymbol{t}_i^A), f(\mathcal{S}_i^A)\rangle\right)}{\sum_{j=1}^{N_A} exp\left(\langle g(\boldsymbol{t}_j^A), f(\mathcal{S}_i^A)\rangle\right)} \quad (12)$$

其中，N_A 是领域 A 中项目的数量，$p(\hat{} y_i^A = A_k)$表示训练样本与项目 A_k 的匹配概率，$\langle x,y\rangle$ 衡量序列嵌入与提示表示之间的相关性。

然后，我们可以通过在所有训练序列上优化标准交叉熵损失函数来学习提示：

$$\mathcal{L}_A = -\frac{1}{|\mathcal{S}_A|}\sum_{i=1}^{|\mathcal{S}_A|} \log p(\hat{y}_i^A = y_i^A), \quad (13)$$

其中，$|\mathcal{S}_A|$ 表示领域 A 中训练序列的数量，y_i^A表示当前训练样本的真实标签。类似地，我们也可以得到领域 B 中提示的优化损失：

$$\mathcal{L}_B = -\frac{1}{|\mathcal{S}_B|}\sum_{i=1}^{|\mathcal{S}_B|} \log p(\hat{y}_i^B = y_i^B), \quad (14)$$

其中，$p(\hat{} y_i^B = y_i^B)$ 表示我们的方法根据给定序列检索到正确物品的概率。

3.5 分离约束

为了使学习到的领域无关提示上下文和领域特定提示上下文能够学习领域信息的不同方面，我们进一步在两个领域中采用共享的领域通用上下文进行双目标学习。该学习目标可以直观地定义为：

$$\mathcal{L} = \mathcal{L}^A + \mathcal{L}^B. \quad (15)$$

然而，由于 NCSR 中的不重叠特性，不同领域的训练样本存在差异，

表 1 我们的 HAMAZON 数据集统计信息。

	电影-图书	食品-厨房
	M 个领域	F 域
项目数量	12,669	24,434
#交互次数	1,052,443	217,409
平均序列长度	9.68	6.37
	B 域	K域
#项目	36,776	24,658
#交互次数	1,060,974	180,657
平均序列长度	9.75	5.29
#序列	108,770	34,143
#训练-序列	81,578	25,608
#测试序列	10,876	5,121
#验证序列	16,316	3,414

而且我们无法将它们一一匹配，这是传统跨域方法的主要假设之一。因此，我们不再学习联合损失 $\mathcal{L}$，而是通过设计两阶段训练方法来联合优化 $\mathcal{L}_A$ 和 $\mathcal{L}_B$ 。具体而言，我们首先使用领域 A 中的训练序列优化 $\mathcal{L}_A$ ，以学习提示中的领域特定上下文和领域无关上下文，其中领域无关上下文在各领域之间共享。然后，除了使用领域 B 中的训练样本学习领域特定特征外，还会根据$\mathcal{L}_B$进一步微调其中的领域无关上下文。由于 $\mathcal{L}_A$ 和 $\mathcal{L}_B$ 具有不同的学习目标，领域特定提示上下文倾向于建模各领域特有的特征。相比之下，领域无关提示上下文倾向于学习跨领域的共有特征。我们的优化方法采用随机梯度下降（SGD）算法。

4 实验设置

在本节中，我们首先介绍实验中拟回答的研究问题，然后详细说明数据集、评估指标、基线方法以及 PLCR 的实现。

4.1 研究问题

实验中所研究的问题如下：

RQ1 我们提出的 PLCR 方法与其他最先进的跨域推荐器相比，表现如何？**RQ2** PLCR 在不同领域中的表现如何？PLCR 能否通过提示调优技术有效利用跨域信息？**RQ3** PLCR 的关键组成部分，即领域特定上下文、领域无关上下文、提示编码器中的注意力机制以及分离约束策略，分别如何影响推荐性能？**RQ4** PLCR 中的超参数如何影响其性能？

4.2 数据集和评估指标

我们在亚马逊的两个子集合上评估所提出的方法及基线方法。亚马逊是一个评论数据集，收集了用户对不同领域产品的评论行为，包括用户 ID、物品 ID、评分、时间戳以及物品描述等。为了研究我们提出的 PLCR 方法在 NCSR 上的表现，我们选取了两对互补领域，即“电影-图书”和“食品-厨房”，作为评估数据集。

更具体地说，“电影-图书”数据集分别记录了亚马逊用户在“电影”和“图书”领域的观看和阅读行为。“食品-厨房”数据集收集了亚马逊用户在“食品”和“厨房”领域的购买记录。由于我们的目标是非重叠跨域推荐，因此无需识别两个领域中的共同用户，并将跨领域的训练样本一一对应组织起来。为过滤无效和噪声数据，我们仅保留交互次数超过 5 次的用户，以及交互频率大于 5 的物品。我们在表 1 中展示了所得数据集的统计信息。

我们的实验将每个序列中的最后一个项目作为真实标签。我们通过随机选取全部序列的 75% 构建训练数据集，选取 10% 作为验证集，其余作为测试集。由于食品-厨房数据集中的测试序列相对较少，我们将验证集和测试集合并用于测试。在评估中，我们采用两种广泛使用的指标，即 HR@K 和 NDCG@K，来衡量我们的方法和基线方法在预测每个测试序列的前 K 个项目时的表现（采用 10 和 20）。

4.3 基线方法

我们将 PLCR与两类基线方法进行比较，即单域序列推荐（序列推荐）方法和跨域序列推荐（CSR）方法。1）单域上的序列推荐方法：

- Session-POP [57]：这是一种简单但有效的推荐方法，倾向于预测每个序列中最热门的物品作为下一个物品进行交互。
- BPR-MF [58]：这是一种常用的基于矩阵分解的推荐方法，采用成对排序目标。我们通过对序列中各项目的潜在因子取平均值来编码序列，并将其应用于序列推荐。
- GRU4REC [59]：该方法将 GRU 应用于序列推荐任务，采用会话并行的小批量训练过程，并优化基于排序的损失函数。
- HRNN [60]：这是 GRU4REC 的改进版本，进一步设计了分层 RNN 结构，并进一步考虑会话之间的序列关系。
- NARM [61]：在此方法中，作者将注意力机制引入会话建模，从用户的历史行为中捕捉其主要意图。

1. https://jmcauley.ucsd.edu/data/amazon

表 2 Movie-Book 和 Food-Kitchen 数据集上的比较结果（%），其中 M 和 B 分别表示 Movie 和 Book 领域，F 和 K 分别表示 Food 和 Kitchen 领域。

方法	M 域				B 域				F-领域				K 域			
	HR		NDCG		HR		NDCG		HR		NDCG		HR		NDCG	
	@10	@20	@10	@20	@10	@20	@10	@20	@10	@20	@10	@20	@10	@20	@10	@20
Session-POP [57]	0.55	1.60	0.20	0.47	0.45	1.25	0.17	0.37	1.12	2.76	0.42	0.84	0.75	1.68	0.29	0.53
BPR-MF [58]	0.80	1.61	0.40	0.61	0.90	1.53	0.44	0.60	2.04	3.64	0.83	1.25	0.09	0.21	0.04	0.07
GRU4REC [59]	2.75	3.80	1.46	1.72	0.81	1.51	0.54	0.71	2.11	3.05	1.01	1.25	0.13	0.49	0.10	0.19
HRNN [60]	2.17	3.24	1.36	1.63	1.13	2.08	0.59	0.82	2.04	2.75	0.99	1.18	0.16	0.26	0.07	0.09
NARM [61]	2.16	3.37	0.93	1.23	1.18	1.80	0.51	0.67	1.59	2.55	0.66	0.90	0.64	1.10	0.27	0.38
Caser [62]	0.66	1.21	0.37	0.45	0.30	0.52	0.17	0.20	1.15	1.94	0.67	0.76	0.75	1.39	0.37	0.52
SRGNN [63]	4.26	6.62	2.27	2.87	2.34	3.19	1.36	1.57	3.35	5.47	1.67	2.19	0.95	1.51	0.58	0.80
SASRec [55]	5.71	9.62	2.72	3.70	3.85	6.37	1.82	2.46	3.23	5.67	1.53	2.15	1.15	1.77	0.57	0.72
CoOp [64]	6.84	11.08	3.32	4.38	4.76	7.58	2.45	3.15	3.15	5.51	1.53	2.12	0.81	1.45	0.37	0.53
π-网络 [65]	4.04	6.00	2.29	2.78	1.62	2.35	1.04	1.23	2.27	3.75	1.14	1.51	0.34	0.61	0.17	0.24
PSJ-net [31]	4.31	6.43	2.56	3.09	1.68	2.33	1.02	1.18	2.79	4.12	1.42	1.75	0.37	0.79	0.20	0.30
DA-GCN [6]	1.72	2.45	0.98	1.16	1.84	2.52	1.13	1.28	2.61	4.26	1.44	1.85	0.84	1.32	0.41	0.53
SASRec（联合） [55]	5.17	8.75	2.56	3.48	3.62	6.24	1.79	2.45	2.87	4.53	1.38	1.80	1.08	1.86	0.52	0.72
PLCR（单一）	7.09	11.05	3.52	4.51	5.23	8.22	2.59	3.34	3.54	5.75	1.76	2.31	1.15	1.77	0.59	0.75
PLCR	**8.06***	**12.69***	**4.06***	**5.22***	**7.21***	**11.47***	**3.62***	**4.70***	**4.67***	**7.43***	**2.17***	**2.86***	**1.16**	**1.97***	**0.62***	**0.83***

与最佳基线结果相比的显著改进用 * 标记（t 检验，$p < .05$）。

- Caser [62]: 这是一种基于卷积神经网络的序列推荐方法。

- SRGNN [63]: 该方法将序列建模为图结构数据，并利用图神经网络捕捉物品之间复杂的转换关系。

- SASRec [55]: 该方法提出了一种基于自注意力的序列模型，用于序列推荐。我们将该方法作为我们方案的骨干网络，首先对其进行预训练，并在提示优化过程中冻结参数。

- CoOp [64]: 该方法旨在为图像识别任务中的预训练视觉-语言模型设计提示。我们将序列视为图像，并使用 SAS-Rec 作为其骨干网络，从而将该方法适配到我们的任务中。

2）跨域序列推荐方法。对于为重叠跨域序列推荐任务提出的方法，我们通过随机复制操作对跨域训练样本进行对齐，从而将其适配到 NCSR。并且，为了模拟非重叠场景，还应用了打乱操作。

- π-net [65]: 这是一种先进的跨域序列推荐方法，利用并行信息共享网络，同时提升两个领域中的推荐效果。

- PSJ-net [31]: 该方法提出了一种分合网络，先将混合表示拆分为角色特定表示，再将其合并以获取跨域表示。

- DA-GCN [6]: 这是一种基于图的跨域推荐方法，构建了用于 CSR 的领域感知注意力图神经网络。

- SASRec（联合） [55]: 这是 SASRec 的跨域版本，使用两个领域的数据进行联合训练。

- PLCR（单一）：这是 PLCR 的一种变体，它将分别在每个域上训练的 SASRec 作为骨干网络。

4.4 实现细节

我们基于 PyTorch平台实现 PLCR，并通过 GeForceGTX TitanXGPU加速训练过程。我们在两个数据集上预训练 SASRec [55] ，并分别将其中的自注意力块和嵌入层作为序列和物品编码器。我们冻结预训练编码器中的参数，并使用小批量随机梯度下降优化器训练提示，训练200 个轮次，其中学习率初始化为 0.0001，批量大小设置为128。对于所有序列，我们将”Movie-Book”数据集的序列最大长度限制为 77，将”Food-Kitchen”数据集的序列最大长度限制为 64。对于超参数，我们将块数量设置为2，将自注意力网络的头数量设置为1，并将提示上下文 M_2 的长度设置为 5。我们在 [1, 5]内搜索提示上下文 M_1 的长度。我们将标签词元位置的选择留作超参数，并在第6.2 节讨论选择这些位置的结果。对于所有潜在因子的维度，我们将其值设置为 50。对于基线方法中的超参数，我们根据相关论文设置其值，并进一步在两个数据集上对其进行微调。

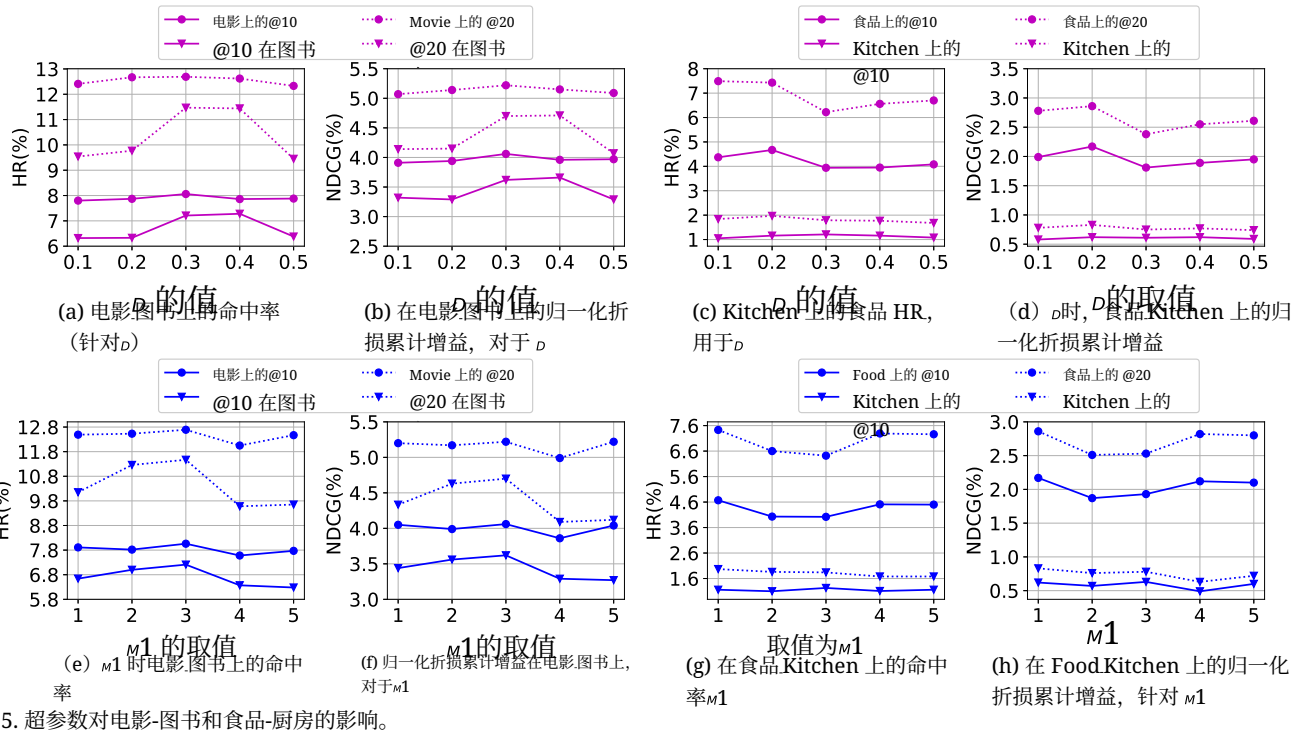
为确保公平比较，所有基线方法均未经过预训练。需要注意的是，尽管我们对 SASRec 进行了预训练，并将其用作骨干网络，但在提示学习期间不会进一步更新它。相反，我们将其视为用于训练提示的固定外部知识；这些提示也不会经过预训练。

5 实验结果（RQ1 和 RQ2）

实验结果如表 2 所示，从中我们可以观察到：1) 我们的 PLCR 方法在两个数据集上都优于所有基线方法，这表明利用提示学习技术解决 NCSR任务的优越性；通过共享相同的提示上下文，该方法能够有效地跨领域传递领域知识。2) PLCR 在两个领域上的表现均优于所有基线方法，展现了其进行双目标跨域推荐的能力。那

表3 电影-图书和食品-厨房数据集上的消融研究结果（%）。

方法	电影域				图书域				食品域				K域			
	HR		NDCG		HR		NDCG		HR		NDCG		HR		NDCG	
	@10	@20	@10	@20	@10	@20	@10	@20	@10	@20	@10	@20	@10	@20	@10	@20
SASRec（联合）	5.17	8.75	2.56	3.48	3.62	6.24	1.79	2.45	2.87	4.53	1.38	1.80	1.08	1.86	0.52	0.72
PLCR（无特定域）	7.83	12.52	3.99	5.17	7.19	11.53	3.59	4.67	4.28	6.96	1.97	2.64	1.14	1.70	0.55	0.69
PLCR（无独立）	7.97	12.67	3.98	5.15	6.49	10.03	3.36	4.25	4.64	7.21	2.10	2.75	1.18	1.64	0.58	0.70
PLCR（无分隔）	7.62	12.47	3.97	5.18	6.45	9.95	3.42	4.30	4.53	7.09	2.11	2.76	1.03	1.80	0.48	0.68
PLCR（无注意力机制）	7.81	12.27	3.94	5.06	6.56	9.80	3.42	4.24	4.37	7.28	2.04	2.77	1.14	1.80	0.58	0.74
PLCR	**8.06**	**12.69**	**4.06**	**5.22**	**7.21**	**11.47**	**3.62**	**4.70**	**4.67**	**7.43**	**2.17**	**2.86**	**1.16**	**1.97**	**0.62**	**0.83**



(a) 电影-图书上的命中率（针对D）

(b) 在电影-图书上的归一化折损累计增益，对于 D

(c) Kitchen 上的食品 HR，用于D

（d）D时，食品Kitchen 上的归一化折损累计增益

（e）$M1$ 时电影-图书上的命中率

(f) 归一化折损累计增益在电影-图书上，对于$M1$

(g) 在食品Kitchen 上的命中率$M1$

(h) 在 Food-Kitchen 上的归一化折损累计增益，针对 $M1$

图5. 超参数对电影-图书和食品-厨房的影响。

也就是说，它可以有效利用跨域信息，并提升两个领域中的推荐效果。3）PLCR的表现优于单域方法（例如GUR4REC、NARM、Caser、SRGNN和SASRec），再次证明了利用跨域信息的益处，这使我们能够做出更好的推荐。PLCR 与 SASRec 之间的差距表明了开展跨域推荐的有效性。4）PLCR 相较于其他近期 SOTA 跨域推荐方法（即 π-net、PSJ-net 和DA-GCN）的改进，证明了提示学习技术在解决面向非重叠用户的跨域推荐任务方面的优越性。由于跨域推荐方法（即 π-net、PSJ-net和 DA-GCN）并非专门为非重叠用户设计，因此无法胜过所有单域方法（例如SRGNN 和SASRec），这可能是由不正确的域匹配造成的。5）我们还注意到，尽管我们使用两个领域的数据来训练SASRec 模型（即SASRec（联合）），但其表现仍比单独训练SASRec 更差，这证明了设计基于提示学习的跨域推荐器的必要性，并且我们无法仅通过简单地将领域数据放在一起转移领域知识。6）PLCR（单一）的性能逊于 PLCR，表明了在统一特征空间中学习提示的重要性，这是使我们能够成功跨领域转移知识的关键点之一。PLCR（单一）能够取得比CoOp 更好的结果，证明了我们的提示在共享领域知识方面的先进性。

6 实验分析

在本节中，我们首先通过开展消融研究来评估不同模型组件的必要性，然后研究关键超参数对 PLCR 的影响，以回答 RQ3 和 RQ4。

6.1 消融研究(RQ3)

为探究不同模型组件的必要性，我们将 PLCR 与其四个变体进行比较：

- PLCR（无特定域）：这是 PLCR 的一种变体，它从提示中移除了领域特定上下文。

这是为了证明领域特定上下文对于适配预训练模型的必要性。

- PLCR（无独立上下文）：此变体移除了PLCR中的领域无关上下文，这有助于证明领域无关上下文在建模领域信息方面的重要性。

- PLCR（无分离约束）：此PLCR变体禁用了其中的分离约束，并单独训练我们的推荐目标。

- PLCR（无注意力）：此版本的PLCR旨在通过从提示编码器中移除注意力网络，评估令牌聚合机制的影响。

消融研究的实验结果如表3所示，从中我们观察到：1）在两个数据集上，PLCR的表现均优于PLCR（无特定域）和PLCR（无独立上下文），这表明领域特定上下文和领域无关上下文有助于提示预训练模型完成非重叠跨域推荐任务。PLCR及其所有变体的表现均优于SASRec（联合），这表明我们的设计能够有效建模用户的跨领域偏好；仅仅合并不同领域的数据，无法有效利用领域信息来增强跨域推荐。2）PLCR的结果优于PLCR（无分离约束），这表明在学习目标中加入分离约束能够提升效果，该约束促使领域无关上下文和领域特定上下文学习领域信息的不同方面。此外，这一结果也表明，我们的提示学习策略能够捕捉用户跨领域的共同兴趣，并利用这些兴趣增强两个领域中的推荐效果。3）PLCR与PLCR（无注意力）之间的差距表明，令牌聚合模块对于学习提示的高维特征至关重要。

6.2 超参数分析（RQ4）

我们进一步探究 PLCR 的关键超参数对两个数据集的影响，并在图5和图6中报告结果。我们探究了三类超参数，即提示编码器中的丢弃率 D 、领域不变上下文的长度 M_1，以及标签词元的位置。图5展示了调整 D和 M_1的实验结果，从中可以观察到 PLCR 的性能变化显著。根据实验结果，我们为电影-图书数据设置$D = 0.3$，为食品-厨房数据设置 $D = 0.2$。M_1 较小意味着我们只通过少量上下文对领域不变特征进行建模。其影响因数据集而异；当 $M_1 = 3$时，电影-图书上的性能最佳；当 $M_1 = 1$时，食品-厨房上的性能最佳。

为探究标签词元位置的影响，我们进一步通过将标签词元置于提示的开头、中间或末尾进行实验。从图6的结果可以看出，当我们根据标签特征更早地截断句子时，PLCR的性能会略有下降。因此，我们将标签词元置于提示的末尾。

7 结论

在这项工作中，我们聚焦于 NCSR，并通过提出一种基于提示学习的跨域推荐器（PLCR）来解决该问题。具体而言，为了在没有任何重叠实体的情况下实现领域之间的领域知识迁移，我们利用提示调优的能力，使用两个领域上的预训练模型，并通过学习由领域特定特征和领域不变特征构成的提示上下文，使其中的外部知识适应不同领域。提示也可以被视为同一领域内所有用户共享的簇级兴趣，而通过在领域之间共享领域不变特征，即可实现领域迁移。为确保学习到的领域无关上下文和领域特定上下文能够对领域信息的不同方面进行建模，我们进一步通过双重学习目标，在学习目标中加入分离约束。我们在亚马逊的两个子集合上进行了实验，实验结果表明，我们的方法在开展跨域推荐方面具有优势。

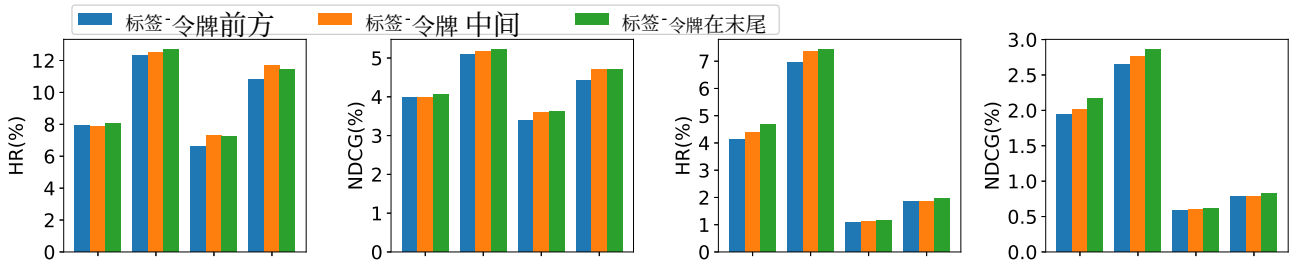
在本工作中，我们主要致力于为具有单一推荐类型的任务开发基于预训练模型的跨域推荐器，而尚未探索其在多种类型推荐任务中的性能。我们将把具有多种类型的跨域推荐作为未来的研究工作之一。

致谢

本工作得到山东省自然科学基金（编号：ZR2022MF257）和澳大利亚研究理事会（编号：DP190101985、FT210100624）的资助。

参考文献

[1] H. Yin、Q. Wang、K. Zheng、Z. Li、J. Yang 和 X. Zhou，“基于社会影响的群体表示学习，用于群体推荐”，载于*2019*年第*35*届*IEEE*数据工程国际会议 *(ICDE)*，2019年，页码 566–577。 [2] T. Chen、H. Yin、G. Ye、Z. Huang、Y. Wang 和 M. Wang，“试试这个：个性化且可解释的替代推荐”，载于第*43*届国际 *ACM SIGIR* 信息检索研究与发展会议论文集，2020年，页码 891–900。[3] Q. Wang、H. Yin、T. Chen、Z. Huang、H. Wang、Y. Zhao 和 N. Q. Viet Hung，“面向资源受限移动设备的下一兴趣点推荐”，载于*2020*年万维网大会论文集，2020年，页码 906–916。 [4] H. Yin 和 B. Cui，社交媒体中的时空推荐。施普林格，2016年。 [5] H. Yin、B. Cui、Z. Huang、W. Wang、X. Wu 和 X. Zhou，“用户兴趣与移动模式联合建模，用于兴趣点推荐”，载于第*23*届 *ACM* 国际多媒体会议论文集，2015年，页码 819–822。 [6] L. Guo、L. Tang、T. Chen、L. Zhu、Q. V. H. Nguyen 和 H. Yin，“DA-GCN：面向共享账户跨域序列推荐的领域感知注意力图卷积网络”，载于*IJCAI*，2021年，页码 2483–2489。 [7] L. Guo、J. Zhang、T. Chen、X. Wang 和 H. Yin，“强化学习增强的共享账户跨域序列推荐”，*IEEE*知识与数据工程汇刊，2022年。 [8] S. Jiang、Z. Ding 和 Y. Fu，“通过深度低秩稀疏集体分解实现异构推荐”，*IEEE*模式分析与机器智能汇刊，第42卷，第5期，页码 1097–1111，2019年。



(a) 电影.图书上的命中率

(b) 电影.图书上的归一化折损累计增益

(c) 食品.Kitchen 上的命中率

(d) 食品.Kitchen 上的归一化折损累计增益

图6. 标签词元在提示中的位置对两个数据集的影响。

[9] W. Liu、J. Su、C. Chen 和 X. Zheng，“通过 Stein 路径利用分布对齐实现跨域冷启动推荐”，神经信息处理系统进展，第34卷，页码 19 223–19 234，2021年。[10] W. Liu、X. Zheng、M. Hu 和 C. Chen，“基于归因对齐的协同过滤，用于基于评论的非重叠跨域推荐”，载于 *2022*年 *ACM Web* 会议论文集，2022年，页码 1181–1190。[11] B. Li、Q. Yang 和 X. Xue，“电影和图书能否协作？通过跨域协同过滤降低稀疏性”，载于第二十一届国际人工智能联合会议，2009年。[12] C. Wang、M. Niepert 和 H. Li，“RecSys-DAN：用于跨域推荐系统的判别式对抗网络”，*IEEE*神经网络与学习系统汇刊，第31卷，第8期，页码 2731–2740，2019年。[13] H. Zhang、X. Kong 和 Y. Zhang，“基于领域自适应的无重叠实体跨域协同推荐”，多媒体系统，页码 1–17，2022年。[14] C. Gao、X. Chen、F. Feng、K. Zhao、X. He、Y. Li 和 D. Jin，“无需共享用户相关数据的跨域推荐”，载于万维网大会，2019年，页码 491–502。[15] D. Perera 和 R. Zimmermann，“CNGAN：用于非重叠用户跨网络用户偏好生成的生成对抗网络”，载于万维网大会，2019年，页码 3144–3150。[16] Q. Zhang、W. Liao、G. Zhang、B. Yuan 和 J. Lu，“用于跨域推荐的深度双重对抗网络”，*IEEE*知识与数据工程汇刊，2021年。[17] H. Kanagawa、H. Kobayashi、N. Shimizu、Y. Tagami 和 T. Suzuki，“通过深度领域自适应实现跨域推荐”，载于信息检索进展，瑞士恰姆，2019年，页码 20–29。[18] J. Cao、X. Lin、X. Cong、J. Ya、T. Liu 和 B. Wang，“DisenCDR：学习用于跨域推荐的解耦表示”，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，页码 267–277。[19] Y. Choi、J. Choi、T. Ko、H. Byun 和 C.-K. Kim，“无需重复用户或上下文的基于评论的领域解耦，用于跨域推荐”，载于第*31*届 *ACM* 国际信息与知识管理会议论文集，2022年，页码 293–303。[20] C. Ge、R. Huang、M. Xie、Z. Lai、S. Song、S. Li 和 G. Huang，“通过提示学习实现领域自适应”，*arXiv* 预印本 *arXiv:2202.06687*，2022年。[21] W. Pan、E. Xiang、N. Liu 和 Q. Yang，“协同过滤中的迁移学习以降低稀疏性”，载于*AAAI* 人工智能会议论文集，第24卷，第1期，2010年，页码 230–235。[22] W. Pan 和 Q. Yang，“异构协同过滤领域中的迁移学习”，人工智能，第197卷，55，2013年，39页。[23] F. Zhu、Y. Wang、J. Zhou、C. Chen、L. Li 和 G. Liu，“一种统一的

用于跨域和跨系统推荐的统一框架，”*IEEE*知识与数据工程汇刊，2021年。[24] Y.-F. Liu、C.-Y. Hsu 和 S.-H. Wu，“通过超结构迁移实现非线性跨域协同过滤”，发表于国际机器学习会议，2015年，第1190–1198页。[25] P. Li 和 A. Tuzhilin，“Ddtcdr：深度双重迁移跨域推荐”，发表于第*13*届国际网络搜索与数据挖掘会议论文集，2020年，第331–339页。[26] M. Liu、J. Li、G. Li 和 P. Pan，“通过双向迁移图协同过滤网络实现跨域推荐”，发表于第*29*届*ACM*国际信息与知识管理会议，2020年，第885–894页。[27] F. Yuan、L. Yao 和 B. Benatallah，“Darec：通过迁移评分模式实现跨域推荐的深度领域自适应”，发表于 *IJCAI*，2019年。[28] F. Zhu、C. Chen、Y. Wang、G. Liu 和 X. Zheng，“双目标跨域推荐框架”，发表于第*28*届*ACM*国际信息与知识管理会议论文集，2019年，第1533–1542页。[29] F. Zhu、Y. Wang、C. Chen、G. Liu 和 X. Zheng，“用于双目标跨域推荐的图结构与注意力框架”，发表于*IJCAI*，2020年，第3001–3008页。[30] Q. Cui、T. Wei、Y. Zhang 和 Q. Zhang，“Herograph：面向多目标跨域推荐的异构图框架”，发表于*ORSUM@ RecSys*，2020年。[31] W. Sun、M. Ma、P. Ren、Y. Lin、Z. Chen、Z. Ren、J. Ma 和 M. De Rijke，“面向共享账户跨域序列推荐的并行分拆合并网络”，*IEEE*知识与数据工程汇刊，2021年。[32] L. Guo、J. Zhang、L. Tang、T. Chen、L. Zhu 和 H. Yin，“面向共享账户跨域序列推荐的时间间隔增强图神经网络”，*IEEE*神经网络与学习系统汇刊，2022年。[33] J. Cao、X. Cong、J. Sheng、T. Liu 和 B. Wang，“对比式跨域序列推荐”，发表于第*31*届*ACM*国际信息与知识管理会议论文集，2022年，第138–147页。[34] M. Ma、P. Ren、Z. Chen、Z. Ren、L. Zhao、P. Liu、J. Ma 和 M. de Rijke，“跨域序列推荐的混合信息流”，*ACM*数据知识发现汇刊（*TKDD*），第16卷，第4期，第1–32页，2022年。[35] P. Cremonesi 和 M. Quadrana，“无重叠数据的跨域推荐：神话还是现实？”，发表于第*8*届*ACM*推荐系统会议论文集，2014年，第297–300页。[36] J. Manotumruksa、D. Rafailidis、C. Macdonald 和 I. Ounis，“关于场所推荐中的跨域迁移”，发表于欧洲信息检索会议，2019年，第443–456页。[37] C. Li、M. Zhao、H. Zhang、C. Yu、L. Cheng、G. Shu、B. Kong 和 D. Niu，“Recguru：通过对抗学习获得用于跨域推荐的广义用户表示”，发表于第*15*届*ACM*国际网络搜索与数据挖掘会议，2022年，第571–581页。[38] B. Li、Q. Yang 和 X. Xue，“通过评分矩阵生成模型实现协同过滤迁移学习”，发表于论文集

第*26*届国际机器学习年会，2009年，第617–624页。[39] A. Krishnan、M. Das、M. Bendre、H. Yang 和 H. Sundaram，“通过上下文不变量进行迁移学习，实现一对多跨域推荐”，发表于第*43*届*ACM SIGIR*信息检索研究与发展国际会议，2020年，第1081–1090页。[40] W. Yu、X. Lin、J. Ge、W. Ou 和 Z. Qin，“通过文本增强领域自适应实现半监督协同过滤”，发表于第*26*届*ACM SIGKDD*知识发现与数据挖掘国际会议论文集，2020年，第2136–2144页。[41] F. Petroni、T. Rockt¨aschel、S. Riedel、P. Lewis、A. Bakhtin、Y. Wu 和 A. Miller，“语言模型是知识库吗？”，发表于*2019*年自然语言处理经验方法会议暨第*9*届国际自然语言处理联合会议（*EMNLP-IJCNLP*）论文集，2019年11月，第2463–2473页。[42] Z. Jiang、F. F. Xu、J. Araki 和 G. Neubig，“我们如何知道语言模型知道什么？”，计算语言学协会汇刊，第8卷，第423–438页，2020年。[43] B. Lester、R. Al-Rfou 和 N. Constant，“规模对参数高效提示调优的力量”，发表于*2021*年自然语言处理经验方法会议论文集，2021年11月，第3045–3059页。[44] X. L. Li 和 P. Liang，“Prefix-tuning：优化用于生成的连续提示”，发表于计算语言学协会第*59*届年会暨第*11*届国际自然语言处理联合会议论文集（第*1*卷：长篇论文），2021年8月，第4582–4597页。[45] P. Liu、W. Yuan、J. Fu、Z. Jiang、H. Hayashi 和 G. Neubig，“预训练、提示与预测：自然语言处理提示方法的系统综述”，*ACM*计算调查，第55卷，第9期，第195:1–195:35页，2023年。[46] T. Shin、Y. Razeghi、R. L. L. IV、E. Wallace 和 S. Singh，“Autoprompt：通过自动生成的提示从语言模型中引出知识”，发表于*2020*年自然语言处理经验方法会议论文集（*EMNLP 2020*，线上举行，*2020*年*11*月*16*日至*20*日），2020年，第4222–4235页。[47] L. Li、Y. Zhang 和 L. Chen，“面向可解释推荐的个性化提示学习”，*ACM*信息系统汇刊（*TOIS*），2023年。[48] S. Geng、S. Liu、Z. Fu、Y. Ge 和 Y. Zhang，“将推荐作为语言处理（RLP）：统一的预训练、个性化提示与预测范式（P5）”，发表于第*16*届*ACM*推荐系统会议论文集，2022年，第299–315页。[49] Z. Cui、J. Ma、C. Zhou、J. Zhou 和 H. Yang，“M6-rec：生成式预训练语言模型是开放式推荐系统”，*arXiv*预印本 *arXiv:2205.08084*，2022年。[50] Y. Wu、R. Xie、Y. Zhu、F. Zhuang、X. Zhang、L. Lin 和 Q. He，“面向序列推荐的个性化提示”，*arXiv*预印本 *arXiv:2205.09666*，2022年。[51] Y. Wu、R. Xie、Y. Zhu、F. Zhuang、A. Xiang、X. Zhang、L. Lin 和 Q. He，“通过提示实现推荐中的选择性公平”，发表于第*45*届*ACM SIGIR*信息检索研究与发展国际会议，2022年，第2657–2662页。[52] X. Xin、T. Pimentel、A. Karatzoglou、P. Ren、K. C hristakopoulou 和 Z. Ren，“重新思考推荐中的强化学习：提示视角”，发表于第*45*届*ACM SIGIR*信息检索研究与发展国际会议，2022年，第1347–1357页。[53] P. Liu、L. Zhang 和 J. A. Gulla，“预训练、提示与推荐：推荐系统中语言建模范式适配的全面综述”，*arXiv*预印本 *arXiv:2302.03735*，2023年。[54] H.-C. Kuo 和 Y.-N. Chen，“通过常识推理进行隐式意图预测与推荐的零样本提示”，*arXiv*预印本 *arXiv:2210.05901*，2022年。[55] W.-C. Kang 和 J. McAuley，“自注意力序列推荐”，发表于*2018*年*IEEE*国际数据挖掘会议（*ICDM*），2018年，第197–206页。[56] A. Vaswani、N. Shazeer、N. Parmar、J. Uszkoreit、L. Jones、A. N. Gomez、Ł. Kaiser 和 I. Polosukhin，“注意力就是你所需要的一切”，神经信息处理系统进展，第30卷，2017年。[57] X. He、L. Liao、H. Zhang、L. Nie、X. Hu 和 T.-S. Chua，“神经协同过滤”，发表于第*26*届国际万维网会议论文集，2017年，第173–182页。[58] S. Rendle、C. Freudenthaler、Z. Gantner 和 L. B. Schmidt-Thieme，《基于隐式反馈的贝叶斯个性化排序》，发表于不确定性人工智能会议论文集，2014年，第452–461页。[59] B. Hidasi、A. Karatzoglou、L. Baltrunas 和 D. Tikk，《使用循环神经网络的基于会话的推荐》，发表于第四届国际学习表征会议（*ICLR 2016*）论文集，波多黎各圣胡安，*2016*年*5*月*2*日至*4*日，会议论文，2016年。[60] M. Quadrana、A. Karatzoglou、B. Hidasi 和 P. Cremonesi，《利用层次循环神经网络个性化基于会话的推荐》，发表于第十一届 *ACM* 推荐系统会议论文集，2017年，第130–137页。[61] J. Li、P. Ren、Z. Chen、Z. Ren、T. Lian 和 J. Ma，《神经注意力基于会话的推荐》，发表于*2017*年 *ACM* 信息与知识管理会议论文集，2017年，第1419–1428页。[62] J. Tang 和 K. Wang，《通过卷积序列嵌入实现个性化 top-n 序列推荐》，发表于第十一届 *ACM* 国际网络搜索与数据挖掘会议论文集，2018年，第565–573页。[63] S. Wu、Y. Tang、Y. Zhu、L. Wang、X. Xie 和 T. Tan，《基于图神经网络的会话推荐》，发表于 *AAAI* 人工智能会议论文集，第33卷，第01期，2019年，第346–353页。[64] K. Zhou、J. Yang、C. C. Loy 和 Z. Liu，《面向视觉语言模型的提示学习》，国际计算机视觉期刊，第130卷，第9期，第2337–2348页，2022年。[65] M. Ma、P. Ren、Y. Lin、Z. Chen、J. Ma 和 M. d. Rijke，《π-net：用于共享账户跨域序列推荐的并行信息共享网络》，发表于第*42*届 *ACM SIGIR* 信息检索研究与发展国际会议论文集，2019年，第685–694页。



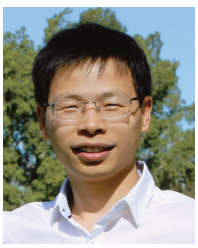
Lei Guo于2015年获得中国山东大学计算机科学博士学位。2018年至2019年，他在昆士兰大学担任访问学者。目前，他是中国山东师范大学副教授和硕士生导师。他是中国信息学会社交媒体处理委员会委员。他的研究兴趣包括信息检索、社交媒体挖掘和推荐系统。



ChunxiaoWang 是山东师范大学信息科学与工程学院计算机科学与技术专业的硕士研究生。她的研究兴趣包括序列推荐和跨域推荐。



XinhuaWang 于2008年获得中国山东师范大学管理科学与工程专业博士学位。他于2008年至2009年在北京大学担任高级访问学者。目前，他是山东师范大学信息科学与工程学院的教授和硕士生导师。他的研究兴趣包括分布式网络和推荐系统。



Lei Zhu 获得了华中科技大学计算机科学博士学位。他是山东师范大学信息科学与工程学院教授。他曾获ACM SIGIR 2019最佳论文荣誉提名奖、ADMA 2020最佳论文奖、ChinaMM2022最佳学生论文奖、ACM中国SIGMM新星奖、山东省留学回国人员创业奖和山东省人工智能优秀青年奖。他的研究

研究兴趣涵盖大规模多媒体内容分析与检索。



尹洪志于2014年获得北京大学计算机科学博士学位。他是昆士兰大学副教授、未来学者。他分别于2016年和2021年获得澳大利亚研究理事会未来学者奖学金和探索早期职业研究人员奖。他的研究兴趣包括推荐系统、用户画像、主题模型、深度学习、社交媒体挖掘和基于位置的服务。