arXiv:2304.03891v1 [cs.IR] 8 Apr 2023

对比式跨域序列推荐

Jiangxia Cao 中国科学院信息工程研究所 中国科学院大学网络空间安全学院
caojiangxia@iie.ac.cn

Xin Cong 中国科学院信息工程研究所 中国科学院大学网络空间安全学院 congxin@iie.ac.cn

Jiawei Sheng 中国科学院信息工程研究所 中国科学院大学网络空间安全学院
shengjiawei@iie.ac.cn

Tingwen Liu*
中国科学院信息工程研究所 中国科学院大学网络空间安全学院
liutingwen@iie.ac.cn

Bin Wang 小米人工智能实验室，小米公司
w
angbin11@xiaomi.com

摘要

跨域序列推荐（CDSR）旨在根据用户在多个领域的历史序列交互来预测未来交互。通常，CDSR 面临的一项关键挑战是如何基于序列内和序列间的物品交互，挖掘准确的跨域用户偏好。现有工作首先仅利用序列内物品交互学习单域用户偏好，然后构建迁移模块以获取跨域用户偏好。然而，这种流程和隐式解决方案会受到所设计迁移模块瓶颈的严重限制，并且忽略了序列间物品关系。本文提出**C^{2}DSR** 来解决上述问题，从而捕捉准确的用户偏好。其核心思想是同时利用序列内和序列间的物品关系，并联合学习单域和跨域用户偏好。具体而言，我们首先利用图神经网络挖掘序列间物品的协同关系，然后采用序列注意力编码器捕捉序列内物品的序列关系。在此基础上，我们设计了两种不同的序列训练目标，以获取用户的单域和跨域表示。此外，我们提出了一种新颖的对比式跨域信息最大化目标，通过最大化单域和跨域用户表示之间的互信息，增强二者之间的相关性。为验证 C^{2}DSR 的有效性，我们首先重新划分了四个电商数据集，然后进行了大量实验，以证明我们的方法有效方法 C^{2}DSR。



图 1：电影域和图书域中用户序列交互的示意图。由相同颜色环绕的电影或书籍表示相似的用户偏好，其中绿色/红色分别代表“浪漫”/“奇幻”偏好。

关键词

跨域序列推荐；对比学习；互信息最大化；

ACM 参考格式：
Jiangxia Cao、Xin Cong、Jiawei Sheng、Tingwen Liu、Bin Wang。2022年。《对比式跨域序列推荐》。载于第*31*届 *ACM* 信息与知识管理国际会议论文集（*CIKM '22*），*2022*年*10*月*17*日至*21*日，美国佐治亚州亚特兰大。ACM，纽约州纽约市，10页。https://doi.org/10.1145/3511808.3557262

CCS 概念

• **信息系统** → **推荐系统**； • **计算方法** → **神经网络**。

*Tingwen Liu 是通讯作者。

本作品采用知识共享署名国际 4.0 许可协议授权。

CIKM '22，*2022*年*10*月*17*日至*21*日，美国佐治亚州亚特兰大©2022年 版权所有者/作者所有。ACM
ISBN 978-1-4503-9236-5/22/10。
https://doi.org/10.1145/3511808.3557262

1 引言

为对动态用户偏好进行建模，序列推荐（SR）旨在根据用户过去的序列交互为其推荐下一个物品，因此在 Amazon 和 YouTube 等许多网络应用中受到了广泛关注。然而，在现实世界中，用户通常只在特定领域表现出部分（或不完整的）偏好，这使得推荐结果实际上会受到观察到的单域历史交互的偏差影响。

为缓解上述问题，研究者提出了跨域序列推荐（CDSR），旨在提升

多个领域的序列推荐性能，同时利用其他相关领域的丰富信息。图 1 展示了一个典型用户在两个领域中的历史交互示例：电影域和图书域。如图所示，该用户最近观看了电影指环王，随后又将相应的书籍指环王 作为后续交互。直观来看，推荐系统不太可能仅依据已观察到的图书交互推荐这本书指环王，因为在单一图书域中，没有明确的相似交互能够体现用户对指环王的偏好。这是因为，用户在每个单一领域中的历史交互可能只反映其部分偏好，容易使推荐系统基于不完整（或单域）偏好产生偏差。幸运的是，综合考察这两个领域，我们可以推断出当前用户相对完整（或跨域）的偏好，即对电影和图书都感兴趣的“爱情”和“奇幻”题材；其中，“奇幻”兴趣可能为做出正确推荐提供积极线索。因此，为了实现更好的无偏推荐，有必要准确捕捉跨域用户偏好。

为识别并迁移领域间有价值的线索，CDSR 研究提出了一种重要范式，即扩展单域序列推荐方法。开创性工作是 π-net [27]，它首先通过对每个单域中的物品交互序列建模来生成单域表示，随后利用门控迁移模块将学习到的单域表示迁移到其他领域。为增强 π-net 中的迁移模块，MIFN [26] 进一步引入外部知识图谱迁移模块，以指导不同领域物品之间的关联。

尽管取得了令人瞩目的改进，这种流水线式范式会分别学习单域用户偏好，通常会生成带有领域偏置的用户表示。直接迁移有偏的单域偏好，难以准确描述跨域用户偏好，容易导致推荐结果不稳定且次优。因此，我们认为有必要**以联合方式学习单域和跨域用户偏好**，以实现无偏的信息迁移。更重要的是，不同领域中的典型用户交互通常体现出相关的偏好，因此我们进一步考虑**单域与跨域用户偏好之间的相关性**。此外，先前的 CDSR 研究 [27, 36] 仅关注对序列内物品关系建模，以捕捉序列模式信号并获得序列表示（即用户表示），却忽略了物品的序列间关系（如图 2 所示），而这些关系能提供有价值的协同信号，从而生成更好的用户表示。因此，我们提出**同时捕捉序列内和序列间的物品关系**以进行表示学习。

为实现上述构想，我们提出了一种对比式跨域序列推荐模型，称为**C^{2}DSR**。我们首先利用图神经网络挖掘序列间物品协同信号，然后采用序列注意力编码器捕获序列内物品的序列信号。基于图模块和注意力模块，我们引入并优化单域和跨域的下一物品预测目标，以获得单域和跨域的

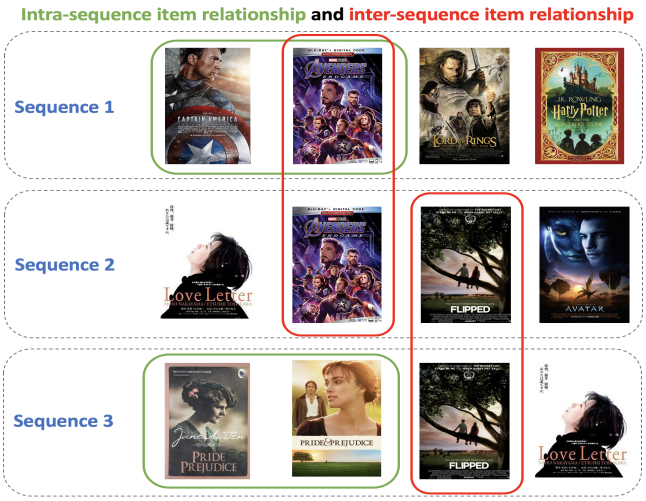


图 2：物品关系示意图。绿色方框表示序列内物品关系所体现的序列模式信号。红色方框表示序列间物品关系所体现的协同信号。

用户表示。此外，我们提出了一种新颖的对比信息最大化目标，鼓励单域和跨域表示具有相关性；该目标利用互信息最大化原理 [13, 24] 来增强它们之间的相关性。为验证该方法的有效性，我们在 Amazon 和 HVIDEO 数据集上，将模型与先前的 CDSR 序列推荐研究进行比较。

总体而言，我们的主要贡献总结如下：

- 我们提出了一种新颖的模型 C^{2}DSR，通过建模序列内和序列间物品关系，同时获得单域和跨域用户表示。
- 我们提出了一种新颖的对比信息最大化目标，通过最大化互信息，鼓励单域和跨域用户表示彼此相关。
- 我们在四个 CDSR 数据集上进行了大量实验，结果表明，我们的 C^{2}DSR 相较于以往最先进的基线方法，取得了稳定且显著的提升。我们的源代码和数据集可在 GitHub 上获取[1]，以供进一步比较。

2 问题定义

在本文中，我们考虑一种通用的 CDSR 场景，其中每个交互序列涉及两个领域，即领域 X和领域 Y。令 $\mathcal{S}$表示整体交互序列集合，其中每个实例 $(S^X, S^Y, S)_u \in \mathcal{S}$属于某个用户 u。对于每个实例，$S^X = [x_1, x_2, \ldots, x_{|S^X|}]$和 $S^Y = [y_1, y_2, \ldots, y_{|S^Y|}]$分别表示对应的单领域交互序列，而 $S = [y_1, x_1, x_2, \ldots, y_{|S^Y|}, \ldots, x_{|S^X|}]$表示按时间顺序合并 S^X和 S^Y得到的跨域交互序列，其中每个 $x \in \mathcal{X}$和 $y \in \mathcal{Y}$都是交互过的物品，$|\cdot|$表示物品总数。请注意，$\mathcal{X}$和 $\mathcal{Y}$表示

[1]https://github.com/cjx96/C2DSR

分别表示领域 X和领域 Y中的全部物品集合。为简洁起见，我们进一步引入三个有向物品—物品矩阵 $\mathrm{A}^X \in \{0,1\}^{|\mathcal{X}|\times|\mathcal{X}|}$，$\mathrm{A}^Y \in \{0,1\}^{|\mathcal{Y}|\times|\mathcal{Y}|}$，$\mathrm{A} \in \{0,1\}^{(|\mathcal{X}|+|\mathcal{Y}|)\times(|\mathcal{X}|+|\mathcal{Y}|)}$ 来表示 $\mathcal{S}$；若x_j是 x_i的下一个物品，则 $\mathrm{A}^X_{ij}=1$，否则 $\mathrm{A}^X_{ij}=0$。

给定观测到的交互序列 $(S^X, S^Y, S)_u$，CDSR 的目标是预测下一个物品：

$$\begin{aligned}&\operatorname{argmax}_{x_i\in\mathcal{X}} \mathrm{P}^X\left(x_i|S^X,S^Y,S\right), \text{if next item} \in \mathcal{X}\\&\operatorname{argmax}_{y_j\in\mathcal{Y}} \mathrm{P}^Y\left(y_j|S^X,S^Y,S\right), \text{if next item} \in \mathcal{Y}\end{aligned} \tag{1}$$

其中，$\mathrm{P}^X(x_i|S^X,S^Y,S) \in \mathbb{R}^{|\mathcal{X}|}$和 $\mathrm{P}^Y(y_j|S^X,S^Y,S) \in \mathbb{R}^{|\mathcal{Y}|}$分别是领域 X和 Y中**候选物品的概率**，选择概率最高的物品作为下一个推荐物品。

3 方法

本节提出模型 **C²DSR**，通过对单域表示和跨域表示进行建模，捕捉并迁移领域间的有用信息。C²DSR 由三个主要部分组成：（1）图结构与注意力编码器，包括嵌入层、图神经网络模块和自注意力模块，用于为每个交互序列生成一系列序列表示（即用户表示）。（2）序列训练目标，包括针对单域和跨域交互序列的两个训练目标，以获得单域和跨域用户表示。（3）对比信息最大化目标，利用互信息最大化原理，增强单域表示与跨域表示之间的相关性。

3.1 图结构与注意力编码器

本节介绍用于捕获 CDSR 数据的图结构注意力序列编码器，它由嵌入层、图神经网络模块和自注意力模块组成。

3.1.1 嵌入初始化层。 在嵌入映射阶段，为了获得三个单序列和跨序列物品交互序列的初始物品表示，我们引入三个参数矩阵 $\mathrm{E}^X \in \mathbb{R}^{|\mathcal{X}|\times d}$、$\mathrm{E}^Y \in \mathbb{R}^{|\mathcal{Y}|\times d}$和 $\mathrm{E} \in \mathbb{R}^{(|\mathcal{X}|+|\mathcal{Y}|)\times d}$，其中 d 表示嵌入维度。此外，为了识别序列的顺序信息，我们定义了一个可学习的位置嵌入矩阵 $\mathrm{T} \in \mathrm{R}^{M\times d}$，以增强输入到自注意力模块的物品嵌入 [5],，其中 M 是交互序列的最大长度，例如 $M=30$。

3.1.2 图神经网络模块。 作为一种建模序列间物品关系的有效方法，我们考虑在所有序列上使用图神经网络 [18] 。受近期研究启发 [10, 42],，我们还移除了卷积矩阵乘法和非线性激活函数，以更好地捕获共现协同过滤信号。具体而言，给定二值有向物品-物品矩阵 $\mathrm{A}^X, \mathrm{A}^Y, \mathrm{A}$，以及初始化嵌入 $\mathrm{G}^X_0=\mathrm{E}^X, \mathrm{G}^Y_0=\mathrm{E}^Y, \mathrm{G}_0=\mathrm{E}$，我们有：

$$\mathrm{G}^X_1=\mathtt{Norm}(\mathrm{A}^X)\mathrm{G}^X_0,\quad \mathrm{G}^Y_1=\mathtt{Norm}(\mathrm{A}^Y)\mathrm{G}^Y_0,\quad \mathrm{G}_1=\mathtt{Norm}(\mathrm{A})\mathrm{G}_0, \tag{2}$$

其中，Norm(·) 表示行归一化函数，G^X_1、G_1，G_1 是卷积输出[2]。通过堆叠 L 层，我们可以得到

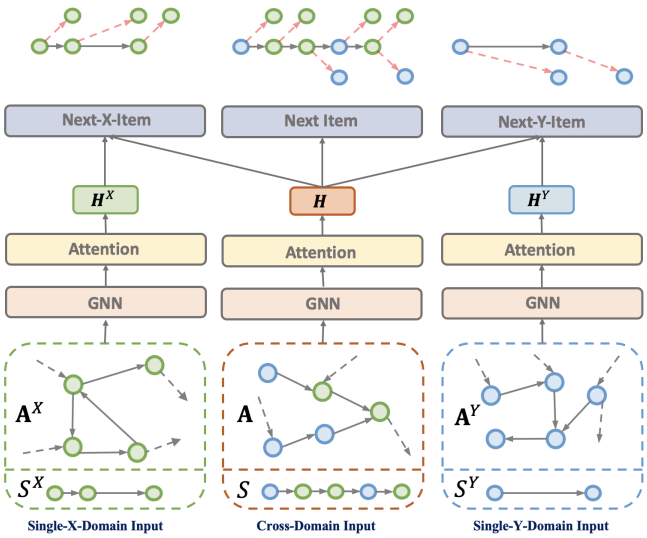


图3：CDSR序列训练目标的一个简单示例。红色虚线表示下一个预测物品。

一系列输出 $\{\mathrm{G}^X_0、\ldots\ldots、\mathrm{G}^X_L\}$、$\{\mathrm{G}^Y_0、\ldots\ldots、\mathrm{G}^Y_L\}$、$\{\mathrm{G}_0、\ldots\ldots、\mathrm{G}_L\}$。为了充分捕捉各层的图结构信息，我们使用 Mean(·) 函数对它们取平均，从而得到物品表示：

$$\mathrm{G}^X=\mathtt{Mean}(\mathrm{G}^X_l)+\mathrm{E}^X, \mathrm{G}^Y=\mathtt{Mean}(\mathrm{G}^Y_l)+\mathrm{E}^Y, \mathrm{G}=\mathtt{Mean}(\mathrm{G}_l)+\mathrm{E}. \tag{3}$$

3.1.3 自注意力模块。 为了捕捉序列内物品关系，我们利用自注意力模块对交互序列进行编码，因为先前的序列推荐研究证明，与 GRU [12] 等其他序列架构相比，注意力机制 [23, 35, 44] 具有更出色的效果。与自注意力模块中的 SASRec [16],类似，该模块包含两种子层：（1）多头自注意力层用于捕捉交互序列中复杂的序列内物品依赖关系；（2）逐点前馈层通过非线性投影生成最终的序列表示。为简洁起见，我们对输入序列采用填充技术2，然后将整体编码过程（包含若干前馈层和自注意力层）表示为：

$$\begin{aligned}\boldsymbol{H}^X=\mathtt{AttEncoder}^X(S^X,\mathrm{G}^X),\quad \boldsymbol{H}^Y=\mathtt{AttEncoder}^Y(S^Y,\mathrm{G}^Y),\\ \boldsymbol{H}=\mathtt{AttEncoder}(S,\mathrm{G}),\end{aligned} \tag{4}$$

其中 $\boldsymbol{H}^X \in \mathbb{R}^{|S|\times d}$，$\boldsymbol{H}^Y \in \mathbb{R}^{|S|\times d}$，$\boldsymbol{H} \in \mathbb{R}^{|S|\times d}$是序列输出；我们采用 AttEncoder 的多个参数对不同的交互序列 S^X、S^Y和 S进行编码，以便更好地适配。

[2]我们在相应位置添加一个 <填充>物品，以分隔单域序列 S^X和 S^Y与 S。例如，S^X = [<填充>, x_1, x_2, <填充>, x_3], S^Y = [y_1,<填充>, <填充>, y_2, <填充>], S = [y_1, x_1, x_2, y_2, x_3], 其中使用常数零向量 0 作为 <填充>物品的嵌入。

3.2 序列训练目标

基于生成的序列输出 $\boldsymbol{H}^X$，$\boldsymbol{H}^Y$，$\boldsymbol{H}$，本节采用两个序列目标对其进行优化，使其分别充当单域表示和跨域表示（见图3）。

3.2.1 单域物品预测。对于单域物品预测，许多序列推荐方法 [12, 16, 38], 采用的最常见策略是直接训练模型，根据观察到的序列推荐下一个物品。以领域 X为例，给定单域填充交互序列 S^X = [<pad>，x_1，x_2，<pad>，……，x_t]及其预期的下一个物品 x_{t+1}。我们采用常用的训练策略来优化编码器，如下所示：

$$\begin{aligned}\mathcal{L}^X_{\text{single}} &= \sum_{S^X\in\mathcal{S}}\sum_{t}\mathcal{L}^X_{\text{single}}(S^X,t)\\ \mathcal{L}^X_{\text{single}}(S^X,t) &= -\log \mathrm{P}^X_{\text{single}}(x_{t+1}|[\text{<pad>},x_1,x_2,\text{<pad>},\ldots,x_t]),\end{aligned} \tag{5}$$

其中，概率 $\mathrm{P}^X\text{single}(x_{t+1}|[\text{<pad>}, x_1, x_2, \text{<pad>}, \ldots\ldots, x_t])$ 被设计为与向量空间中所有物品 $x \in \mathcal{X}$ 和给定序列之间的相似度成正比。基于学习到的表示 $\boldsymbol{H}^X$和 $\boldsymbol{H}$，我们按如下方式计算单域X预测概率 $\mathrm{P}^X\text{single}(\cdot)$（领域 Y同理）：

$$\mathrm{P}^X_{\text{single}}(x_{t+1}|[\ldots,x_t]) = \texttt{Softmax}(\boldsymbol{h}^X_t\mathrm{W}^X + \boldsymbol{h}_t\mathrm{W}^X)_{x_{t+1}} \tag{6}$$

其中，$\boldsymbol{h}^X_t \in \mathbb{R}^{1\times d}$，$\boldsymbol{h}_t \in \mathbb{R}^{1\times d}$表示位置 t 处的序列表示，$\mathrm{W}^X \in \mathbb{R}^{d\times|\mathcal{X}|}$是用于预测的可学习参数矩阵。具体而言，$\texttt{Softmax}(\boldsymbol{h}^X_t\mathrm{W}^X+\boldsymbol{h}_t\mathrm{W}^X) \in \mathbb{R}^{|\mathcal{X}|}$表示所有物品 $x \in \mathcal{X}$ 的非负预测概率，其总和为 1。我们从中选取 x_{t+1} 对应的概率作为最终预测分数。请注意，这些公式（式 (5-6)）同样适用于单-Y-域场景，即 $\mathcal{L}^Y\text{single}$。

具体而言，这种训练策略在单域场景中能够取得理想的效果，但难以对跨域交互序列进行建模。例如，假设我们合并两个单域序列，得到跨域物品序列“[电影、电影、电影、电影] → 书籍”。由于观测到的物品始终是电影类型，上述训练策略会通过优化 $\text{Softmax}(\cdot) \in \mathbb{R}^{|\mathcal{X}|+|\mathcal{Y}|}$来最小化所有书籍类型物品的概率，即使某些书籍物品与最新的电影物品具有很强的相关性，这也可能会限制模型的有效性。这一观察促使我们设计一种更均衡的训练策略，用于跨域交互序列。

3.2.2 跨领域物品预测。在跨领域交互序列中，用户通常表现出多样化的偏好，而一个领域中的偏好可能会影响其在另一领域中的后续交互（例如，观看电影指环王可能会促使用户阅读书籍指环王）。此外，不同领域中的交互数量各不相同。为避免预测结果受数据丰富的领域主导，需要采用平衡的目标函数。也就是说，当模型预测下一个电影物品时，也应保留其在图书域中的预测能力。遵循这一思路，给定下一个物品为 x_{t+1} 或 y_{t+1}，我们

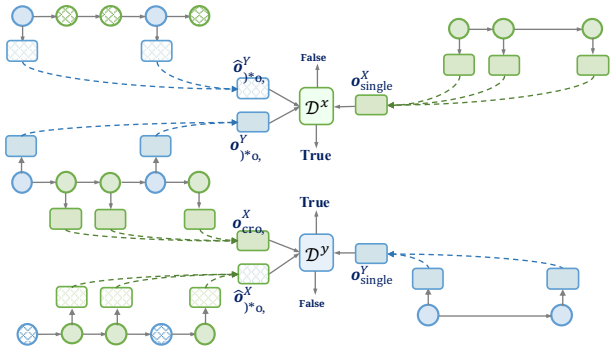


图4：我们对比信息最大化方法的示意图。空心的绿色/蓝色圆圈表示领域 X/Y中的随机物品。

跨域序列 S 的训练策略定义如下：

$$\begin{aligned}\mathcal{L}_{\text{cross}} &= \sum_{S\in\mathcal{S}}\sum_{t}\mathcal{L}_{\text{cross}}(S,t),\\ \mathcal{L}_{\text{cross}}(S,t) &= \begin{cases}-\log \mathrm{P}^X_{\text{cross}}(x_{t+1}|[y_1,x_1,x_2,\ldots,x_t]),\\ -\log \mathrm{P}^Y_{\text{cross}}(y_{t+1}|[y_1,x_1,x_2,\ldots,x_t]),\end{cases}\end{aligned} \tag{7}$$

其中，我们利用学习到的表示 $\boldsymbol{H}$ 来实现预测概率$\mathrm{P}^X\text{cross}(\cdot)$，$\mathrm{P}^Y\text{cross}(\cdot)$，如下所示：

$$\begin{aligned}\mathrm{P}^X_{\text{cross}}(x_{t+1}|[y_1,x_1,x_2,\ldots,x_t]) &= \texttt{Softmax}(\boldsymbol{h}_t\mathrm{W}^X)_{x_{t+1}},\\ \mathrm{P}^Y_{\text{cross}}(y_{t+1}|[y_1,x_1,x_2,\ldots,x_t]) &= \texttt{Softmax}(\boldsymbol{h}_t\mathrm{W}^Y)_{y_{t+1}},\end{aligned} \tag{8}$$

其中，W^X是$\mathrm{P}^X\text{single}(\cdot)$中的相同参数矩阵。在上述公式(7)中，我们将损失函数分解为两个相等且独立的部分，分别针对领域 X 和 Y 进行优化。这样，即使交互序列中包含许多来自另一领域的连续物品，也能保持对一个领域的预测能力。

至此，我们介绍了单域和跨域序列物品预测目标。如图3所示，这两类目标利用学习到的表示实现截然不同的目的。具体而言，$\boldsymbol{H}^X$、$\boldsymbol{H}^Y$ 仅用于预测下一个单域物品，而 $\boldsymbol{H}$ 旨在预测两个领域中的物品。因此，通过优化公式(5)和公式(7)，$\boldsymbol{H}^X$、$\boldsymbol{H}^Y$ $\boldsymbol{H}$ 倾向于编码单域用户偏好，而 $\boldsymbol{H}^Y$ $\boldsymbol{H}$ 则被鼓励作为跨域用户偏好发挥作用。

3.3 对比信息最大化目标

由于单域表示 $\boldsymbol{H}^X$、$\boldsymbol{H}^Y$是根据序列 S^X、S^Y独立学习得到的，因此它们往往只能推断用户在单个域中的部分偏好。如前所述，融入跨域偏好有助于生成更好的推荐结果。因此，受信息最大化原理 [3, 40], 的启发，我们提出了一种新颖的对比信息最大化目标，以提升单域表示与跨域表示之间的相关性。

3.3.1 单域与跨域原型表示。为了在不同的交互序列中表示用户的整体偏好S^X，S^Y，S，我们为其生成原型表示 [34]。原型表示的构想借鉴了原型网络 [37],，该网络生成原型来表示

同类型样本。我们通过简单的均值运算，将序列表示的质心用作原型表示。例如，要获得单域原型表示，具体过程可表述为：

$$\boldsymbol{o}^X_{\text{single}} = \texttt{Mean}(\boldsymbol{H}^X), \qquad \boldsymbol{o}^Y_{\text{single}} = \texttt{Mean}(\boldsymbol{H}^Y), \tag{9}$$

其中，$\boldsymbol{o}^X\text{single} \in \mathbb{R}^{1\times d}$和 $\boldsymbol{o}^Y\text{single} \in \mathbb{R}^{1\times d}$分别是 S^X和 S^Y 的 X域和Y域原型表示。

对于跨域交互序列 S，我们通过对相应领域的物品表示取平均，生成两个跨域原型表示：

$$\boldsymbol{o}^X_{\text{cross}} = \texttt{Mean}(\{\boldsymbol{h}_t : S_t \in \mathcal{X}\}), \quad \boldsymbol{o}^Y_{\text{cross}} = \texttt{Mean}(\{\boldsymbol{h}_t : S_t \in \mathcal{Y}\}), \tag{10}$$

其中，$\boldsymbol{o}^X\text{cross}$ 和 $\boldsymbol{o}^Y\text{cross}$ 是领域 X和 Y的跨域原型表示，它们编码了用户基于两个领域信息形成的整体偏好。

3.3.2 信息最大化目标。 获得原型表示后，我们遵循 DIM [13] 的直觉，采用对比目标来区分来自联合分布的样本（正样本）与来自边缘分布乘积的样本（负样本），以构建对比信息最大化目标。为了从正向跨域交互序列 S中生成负样本，我们针对领域 X和 Y分别采用负采样技巧，设计了两个扰动函数 Corrupt^X和 Corrupt^Y。我们的扰动函数具体如下：

$$\begin{aligned} \widehat{S}^X &= \texttt{Corrupt}^X(S) = [\widehat{y}_1, x_1, x_2, \widehat{y}_2, \dots], \\ \widehat{S}^Y &= \texttt{Corrupt}^Y(S) = [y_1, \widehat{x}_1, \widehat{x}_2, y_2, \dots], \end{aligned} \tag{11}$$

其中，$\widehat{x}$和 $\widehat{y}$是从相应领域中随机选取的物品，$\widehat{S}^X$和 $\widehat{S}^Y$是扰动后的跨域交互序列。根据公式 (4) 和公式 (10)，我们分别为 $\widehat{S}^X$和 $\widehat{S}^Y$生成原型表示 $\widehat{\boldsymbol{o}}^X\text{cross}$ 和 $\widehat{\boldsymbol{o}}^Y\text{cross}$。

考虑到用户可能在两个领域之间存在相关偏好，我们希望来自两个领域的原型表示具有内在相关性。以领域 X为例，我们希望单一-X-领域表示 $\boldsymbol{o}^X\text{single}$ 与包含真实 X领域物品的 $\boldsymbol{o}^Y\text{cross}$ 相关，而与包含虚假 X领域物品的 $\widehat{\boldsymbol{o}}^Y\text{cross}$ 不相关。这种设计不仅能强化两个领域之间的相关性，还能使跨域表示（例如 $\boldsymbol{o}^Y\text{cross}$）聚焦于领域 X中的真实序列交互。因此，我们将信息最大化目标 $\mathcal{L}^X\text{disc}$ 定义为（注意，该定义对领域 Y 同样成立，并得到 $\mathcal{L}^Y\text{disc}$ ）：

$$\mathcal{L}^X_{\text{disc}} = \sum_{(S^X,S^Y,S)_u \in \mathcal{S}} -\Big(\log \mathcal{D}^X(\boldsymbol{o}^X_{\text{single}}, \boldsymbol{o}^Y_{\text{cross}}) + \log\big(1 - \mathcal{D}^X(\boldsymbol{o}^X_{\text{single}}, \widehat{\boldsymbol{o}}^Y_{\text{cross}})\big)\Big) \tag{12}$$

其中，$\mathcal{D}_X$ 可视为二元判别器，通过双线性映射函数度量单域和跨域原型表示对：

$$\mathcal{D}^X(\boldsymbol{o}^X_{\text{single}}, \boldsymbol{o}^Y_{\text{cross}}) = \sigma\big(\boldsymbol{o}^X_{\text{single}} \mathrm{W}^X_{\text{disc}} (\boldsymbol{o}^Y_{\text{cross}})^\top\big), \tag{13}$$

其中，$\mathrm{W}^X\text{disc} \in \mathbb{R}^{d\times d}$是可学习的参数矩阵，$\sigma$ 是 Sigmoid(·) 函数。正如先前研究所讨论的那样 [3, 40], ，式（12）中的二元交叉熵损失是一种有效的互信息（MI）估计器。它可以最大化单域表示与跨域表示之间的互信息，并捕捉它们之间的相关性，因为它衡量联合分布与边缘分布乘积之间的 Jensen–Shannon（JS）散度。此外，它遵循生成对抗网络（GAN） [6], 中形式化的极大极小目标，而 GAN 目标与 JS 散度密切相关，可用于互信息估计。

3.4 模型训练与评估

C²DSR 的总损失函数包含两种类型：

$$\mathcal{L} = \underbrace{\lambda(\mathcal{L}_{\text{cross}} + \mathcal{L}^X_{\text{single}} + \mathcal{L}^Y_{\text{single}})}_{\text{Sequential training objective}} + \underbrace{(1-\lambda)(\mathcal{L}^X_{\text{disc}} + \mathcal{L}^Y_{\text{disc}})}_{\text{Contrastive infomax objective}} \tag{14}$$

其中，λ 是调和因子。我们的 C²DSR 可以采用小批量方式 [17], 进行优化，其时间复杂度[3] 与其他基于注意力架构的序列推荐方法相近。

在评估阶段，我们利用相应的单域和跨域表示进行预测。例如，给定最新表示 $\boldsymbol{h}^X_{|S|}$ 和 $\boldsymbol{h}_{|S|}$，我们选择域 X 中预测得分最高的项目作为推荐的下一项（见第 4.2.1 节）：

$$\begin{aligned} &\text{argmax}_{x_i \in \mathcal{X}} \mathrm{P}^X\left(x_i | S^X, S^Y, S\right), \quad \text{where} \\ &\mathrm{P}^X(x_i | S^X, S^Y, S) = \texttt{Softmax}\big(\boldsymbol{h}^X_{|S|} \mathrm{W}^X + \boldsymbol{h}_{|S|} \mathrm{W}^X\big)_{x_i}. \end{aligned} \tag{15}$$

预测函数同样适用于域 Y，从而实现式（1）中的最终任务目标。

4 实验

在本节中，我们将 C²DSR 与多种方法进行比较，以评估其性能。此外，我们还对模型变体进行了详细研究，以展示模型组件的有效性，并分析超参数的影响。

4.1 数据集

与许多跨域推荐方法一样，我们也采用公开可用的 Amazon[4]（电商平台）和 HVIDEO[5]（电视服务平台）数据集来构建 CDSR 场景。遵循以往研究 [26, 27], ，我们选择以下六个领域，为实验生成三个 CDSR 场景："食品-厨房"（Amazon）、"电影-书籍"（Amazon）和"娱乐-教育"（HVIDEO）。为与以往方法进行公平比较，我们首先提取在两个领域中均有交互的用户，然后过滤掉交互次数少于 10 次的部分用户和物品。此外，为满足序列约束，我们保留在一段时间内（例如，"电影-书籍"场景按月，"食品-厨房"场景按年）每个领域至少包含 3 个物品的跨域交互序列。在训练集/验证集/测试集划分方面，我们不同于以往随机选择样本来构建训练集/验证集/测试集的做法，因为后者可能导致信息泄漏问题。我们通过计算

[3]在相同的运行环境下，我们实测发现，在 Tesla T4 GPU 上使用"Food-Kitchen"数据集进行训练时，C²DSR 和 SASRec 每个训练轮次分别耗时约 54 秒和 40 秒。详情见实现设置部分。[4]http://jmcauley.ucsd.edu/data/amazon/index_2014.html [5] https://bitbucket.org/Catherine_Ma/pinet_sigir2019/src/master/HVIDEO/

表 1：三个CDSR场景的统计信息。

场景	物品数	训练集数	#有效	#测试	平均长度
Food	29,207	34,117	2,722	2,747	9.91
厨房	34,886		5,451	5,659	
电影	36,845	58,515	2,032	1,978	11.98
Book	63,937		5,612	5,730	
娱乐	8,367	120,635	4,525	4,485	29.94
教育	11,404		2,404	2,300	

验证集/测试集中那些发生在相应用户训练集交互序列之前的用户交互序列（使用未来的交互序列预测过去的交互），分析了这种不恰当的设置，并发现预处理后的 Amazon 数据集中约有 60% 的验证集/测试集样本存在这一问题。在我们的工作中，为避免该问题，我们将用户最新的交互序列等分为验证集/测试集，其余交互序列用于训练集。CDSR 场景中修正后数据集的统计信息汇总于表 1。

4.2 实验设置

4.2.1 评估协议。遵循先前的研究 [16, 35, 44],，我们也采用留一法来计算推荐性能。为确保评估无偏，我们遵循 Rendle 的研究 [19]，为每个验证/测试样例计算 1,000 个分数（包括 999 个负样本物品和 1 个正样本物品）。然后，我们根据 MRR（平均倒数排名）[41],、NDCG@{5, 10}（归一化折损累积增益）[15] 和 HR@{1, 5, 10}（命中率），报告 1,000 个物品排名列表的*Top-K* 推荐性能。

4.2.2 对比基线方法。**本节介绍四类基线方法及其用于适配的关键操作。**

传统推荐基线：**(1)BPRMF** [30] 是一种广为人知的方法，它设计了一种成对排序损失函数，用于学习用户和物品的表示。(2) **ItemKNN** [31] 遵循度量学习的思路，假设用户交互过的物品之间的相似度高于尚未交互过的物品之间的相似度。对于这些方法，我们忽略用户—物品交互序列的序列约束，并在混合的用户—物品对数据集上训练它们。

跨域推荐基线：(1) **NCF-MLP** [11] 是一种著名的方法，通过 MLP 网络学习表示。为了适配两个领域，我们采用该方法，通过两个独立的基础 MLP 网络学习用户/物品表示，并共享一个初始化的用户嵌入层。(2) **CoNet** [14] 是一种经典的跨域推荐方法，它首先通过两个基础网络对两个领域的交互进行建模，然后通过连接两个基础网络的跨网络传递信息。对于这些方法，我们同样忽略用户—物品交互序列的序列约束。

序列推荐基线方法：(1) **GRU4Rec** [12] 采用 GRU 架构对交互序列进行建模，以实现序列推荐。(2) **SAS-Rec** [16] 是序列推荐领域最先进的基线方法之一，它使用自注意力机制对交互序列进行建模。(3)**SR-GNN** [43] 是率先将图神经网络应用于序列推荐的工作之一，旨在捕捉物品之间的高阶关系。对于这些方法，我们保留序列约束，并直接在混合交互序列数据集上对其进行训练。

跨域序列推荐基线方法：(1) π-**Net** [27]是 CDSR 的开创性工作，设计了一种新颖的门控循环模块，用于对不同领域的知识进行建模和迁移。(2) **PSJNet** [36] 是在 π-Net基础上扩展而来的，通过引入并行拆分-合并方案，在不同领域之间迁移用户的不同意图。(3)**MIFN** [26] 是近期提出的一种 CDSR 方法，它构建了一个知识图谱，以引导其他领域物品之间的关联，从而实现跨领域信息迁移。对于这些方法，我们使用**自注意力模块**作为序列编码器。

4.2.3 实现与超参数设置。为确保比较公平，我们采用与 MIFN 相同的超参数设置。对于所有方法，我们首先将嵌入维度 d 和小批量大小 B 均设为 256，丢弃率设为 0.3，L_2 正则化系数从 {0.0001, 0.00005, 0.00001} 中选取，学习率从 {0.001, 0.0005, 0.0001} 中选取，训练轮数固定为 100 以获得最佳结果，调和因子 λ 从 0.1 到 0.9 以 0.1 为步长选取，图神经网络的深度 L 从 {1, 2,3, 4} 中选取，并使用 Adam [17] 优化器更新所有参数。此外，按照 SASRec 的建议，本研究采用两个单头注意力块和学习得到的位置嵌入；根据相关文献，π-net 和 PSJNet 的通道数设为 5。我们根据验证集上最高的平均倒数排名表现，选取最佳评估结果。

4.3 性能比较

表 2、表 3 和表 4 展示了各方法在“Food-Kitchen”、“Movie-Book”和“Entertainment-Education” CDSR 场景中的性能。需要注意的是，由于我们无法获得 HVIDEO 数据集上的物品知识图谱，因此没有提供 MIFN 在“Entertainment-Education”上的结果。最佳性能以粗体显示，第二佳性能以下划线标示。基于这些结果，我们可以得到一些有价值的观察：(1) 对于跨领域推荐基线方法，CoNet 和 NCF-MLP 的性能优于传统基线方法 BPRMF 和 ItemKNN，这验证了考虑领域之间的差异并在领域之间迁移此类知识，有助于实现更好的领域适配。(2) 对于序列推荐基线，GRU4Rec、SASRec 和 SR-GNN 在混合序列推荐数据集上展现出良好的性能。同时，这些方法显著优于 BPRMF、ItemKNN、NCF-MLP 和 CoNet。其原因在于，捕捉交互的序列特征能够为实现精准推荐提供有价值的线索。此外，显然，在“Entertainment-Education” CDSR 场景中，SASRec 和 SR-GNN 的性能比 GRU4Rec 更稳定。根据我们的统计，我们认为这可能是由于序列长度造成的：该场景的序列比其他场景长得多（如表 1 所示），而且自注意力编码器相比 GRU 具有更强的长序列建模能力。(3) 对于 CDSR 基线方法，π-Net、PSJNet 和 MIFN 的性能优于其他基线方法，这表明跨域信息同样有助于提升推荐性能。此外，这些方法表现出明显不同的预测性能，说明迁移策略对于建模跨领域用户偏好至关重要。(4) 我们的

表 2：食品-厨房场景中的实验结果（%）。

方法	食品领域推荐						厨房领域推荐					
	MRR	NDCG		HR			MRR	NDCG		HR		
		@5	@10	@1	@5	@10		@5	@10	@1	@5	@10
BPRMF	4.10	3.55	4.03	2.42	4.51	5.95	2.01	1.45	1.85	0.73	2.18	3.43
ItemKNN	3.92	3.51	3.97	2.41	4.59	5.98	1.89	1.28	1.75	0.58	1.99	3.26
NCF-MLP	4.49	3.94	4.51	2.68	5.10	6.86	2.18	1.57	2.03	0.91	2.23	3.65
CoNet	4.13	3.61	4.14	2.42	4.77	6.35	2.17	1.50	2.11	0.95	2.07	3.71
GRU4Rec	5.79	5.48	6.13	3.63	7.12	9.11	3.06	2.55	3.10	1.61	3.50	5.22
SASRec	7.30	6.90	7.79	4.73	8.92	11.68	3.79	3.35	3.93	1.92	4.78	6.62
SR-GNN	7.84	7.58	8.35	5.03	9.88	12.27	4.01	3.47	4.13	2.07	4.80	6.84
π-网络	7.68	7.32	8.13	5.25	9.25	11.75	3.53	2.98	3.73	1.57	4.34	6.67
PSJNet	8.33	8.07	8.77	5.73	10.28	12.45	4.10	3.68	4.32	2.14	5.17	7.15
MIFN	8.55	8.28	9.01	6.02	10.43	12.71	4.09	3.57	4.29	2.21	4.86	7.08
C²DSR	**8.91**	**8.65**	**9.71**	**5.84**	**11.24**	**14.54**	**4.65**	**4.16**	**4.94**	**2.51**	**5.74**	**8.18**

表3：E 在 Movie-Book 场景上的实验结果（%） **ario.**

方法	电影领域推荐						图书领域推荐					
	MRR	NDCG		HR			MRR	NDCG		HR		
		@5	@10	@1	@5	@10		@5	@10	@1	@5	@10
BPRMF	2.96	2.18	2.80	1.41	3.03	4.95	1.27	0.85	1.17	0.48	1.23	2.25
ItemKNN	2.92	2.17	2.88	1.26	3.13	5.35	1.26	0.86	1.10	0.48	1.25	2.00
NCF-MLP	3.05	2.26	2.96	1.41	3.13	5.30	1.43	1.06	1.26	0.62	1.39	2.18
CoNet	3.07	2.42	3.01	1.31	3.48	5.35	1.45	1.04	1.28	0.64	1.44	2.19
GRU4Rec	3.83	3.14	3.73	2.27	3.39	5.40	1.68	1.34	1.52	0.91	1.81	2.37
SASRec	3.79	3.23	3.69	2.37	3.99	5.20	1.81	1.41	1.71	0.95	1.83	2.75
SR-GNN	3.85	3.27	3.78	2.22	4.19	5.81	1.78	1.40	1.66	0.89	1.90	2.72
π-网络	4.16	3.72	4.17	2.52	4.75	6.11	2.17	1.84	2.03	1.43	2.25	2.84
PSJNet	4.63	4.06	4.76	2.78	5.30	7.53	2.44	2.07	2.35	1.66	2.58	3.28
MIFN	5.05	4.21	5.20	2.83	5.51	8.29	2.51	2.12	2.31	1.60	2.46	3.07
C²DSR	**5.54**	**4.76**	**5.76**	**3.13**	**6.47**	**9.55**	**2.55**	**2.17**	**2.45**	**1.71**	**2.84**	**3.75**

表 4：娱乐-教育场景下的实验结果（%）。

方法	娱乐领域推荐						教育领域推荐					
	MRR	NDCG		HR			MRR	NDCG		HR		
		@5	@10	@1	@5	@10		@5	@10	@1	@5	@10
BPRMF	45.97	47.38	50.11	35.98	57.65	66.08	46.50	47.51	49.27	38.69	54.86	60.26
ItemKNN	47.81	49.24	52.01	37.91	59.44	67.93	46.22	47.23	49.22	38.08	54.86	61.04
NCF-MLP	44.94	47.57	50.61	31.66	61.73	71.08	46.24	48.73	50.66	35.17	60.56	66.43
CoNet	45.76	48.31	51.63	32.30	62.45	72.68	47.83	50.11	52.22	36.60	61.65	68.04
GRU4Rec	45.61	47.48	51.46	32.73	61.06	73.35	51.35	53.88	56.21	39.95	66.13	73.21
SASRec	50.44	52.67	56.10	37.05	66.39	76.92	53.69	55.87	58.64	41.86	68.04	76.56
SR-GNN	50.67	52.77	56.47	37.43	66.30	77.17	54.74	56.73	59.69	43.08	68.43	77.47
π-网络	52.68	54.88	57.63	40.91	67.15	75.11	55.05	57.23	59.32	44.26	68.21	74.65
PSJNet	53.50	**57.57**	**60.07**	**42.52**	68.94	76.56	55.94	58.18	60.15	**45.21**	69.01	75.08
C²DSR	**53.87**	56.20	59.35	40.89	**69.45**	**79.08**	**56.72**	**59.05**	**61.56**	45.13	**71.04**	**79.21**

C²DSR 在许多指标上都大幅优于所有基线方法，证明了我们的模型在 CDSR 任务中的高有效性。这一事实表明，利用序列内和序列间的物品关系来建模单领域和跨领域用户偏好，对于 CDSR 至关重要。与先前的工作（π-Net、PSJNet）相比，采用显式方式引导信息迁移似乎

比起直接隐式建模迁移模块更有用，例如使用 MIFN 的跨域物品知识图谱、我们提出的序列目标和对比信息最大化目标。（5）一个有趣的现象是，“Entertainment-Education”上的结果远高于其他领域。这是因为用户有时会在电视 [29] 中重复进行某些行为

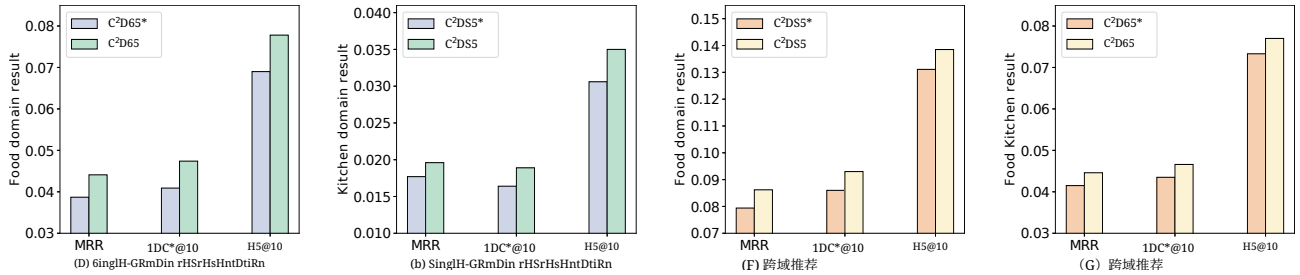


图5： Food-Kitchen 上单域表示和跨域表示的预测结果。

平台上，例如在一段时间内连续观看同一部电视剧，这使得推荐变得容易。

4.4 模型变体讨论

本节考察模型组件的有效性，以及所提出的对比信息最大化目标的可扩展性。我们进行了若干模型变体实验，表5分别给出了这些模型变体在“Food-Kitchen”和“Entertainment-Education”上的结果。具体而言，我们用“++”表示模型融合了我们的图神经网络，并采用所提出的跨域序列训练目标进行训练。我们用“∗”表示模型未采用所提出的信息最大化目标进行训练。此外，C²DSR(GRU4Rec)采用GRU4Rec作为序列编码器，但使用相同的信息最大化目标。

从表5中，我们得到以下几点有启发性的观察：(1) 标记为“++”的方法显著优于原始方法，这表明，对跨序列和序列内项目关系进行建模，并采用所提出的跨域目标进行训练，有助于拟合跨域交互序列。(2) 标记为“∗”的方法始终优于对应的“++”方法，这表明联合建模单域和跨域用户偏好对于CDSR任务也至关重要。(3) 与其他基于注意力的基线方法相比，模型变体C²DSR(GRU4Rec)的表现也令人满意，这表明所提出的信息最大化目标可以无缝融入其他序列编码器，通过捕获单域与跨域用户表示之间的相关性来提升其有效性。

4.5 信息最大化影响的讨论

在本节中，为了进一步验证所提出的对比信息最大化目标能够增强单域和跨域表示，我们对 C²DSR 与 C²DSR* （训练时未使用信息最大化目标）进行了分析。如图5所示，我们仅利用单域表示或跨域表示来测试各领域中的预测能力。由此可见：（1）跨域表示的预测能力强于单域表示，这表明考虑其他相关领域对于增强各单域序列推荐至关重要。（2）与 C²DSR* 相比，我们提出的信息最大化目标能够同时增强单域和跨域表示的预测能力。我们认为，

表5：Food-Kitchen 上各模型变体的结果。

模型变体	食品域			厨房域		
	平均倒数排名	NDCG@10	HR@10	平均倒数排名	NDCG@10	HR@10
GRU4Rec	5.79	6.13	9.11	3.06	3.10	5.22
GRU4Rec++	6.92	7.18	10.10	3.21	3.28	5.63
C²DSR(GRU4Rec)*	6.83	7.26	10.72	3.57	3.68	6.10
C²DSR(GRU4Rec)	7.68	8.02	11.60	3.92	4.02	6.54
SASRec	7.30	7.79	11.68	3.79	3.93	6.62
SASRec++	8.09	8.70	13.11	4.20	4.45	7.55
C²DSR*	8.73	9.36	13.66	4.41	4.55	7.70
C²DSR	8.91	9.71	14.54	4.65	4.94	8.18

原因在于，我们的对比信息最大化目标能够使单域表示感知用户的完整偏好，并促使跨域表示在两个领域中提供更具普适性的偏好。

4.6 超参数分析

本节研究调和因子 λ 和图神经网络深度 L的参数敏感性。

对于超参数 λ，图 6(a) 和 6(b) 分别展示了模型在“食品”域和“厨房”域上的预测表现，以 NDCG@10 和 HR@10 衡量。由此可见，与 $\lambda = 1.0$（此处指未使用我们的对比信息最大化目标进行训练的情况）相比，我们的模型取得了稳定的提升。具体而言，当λ 处于 $[0.3, 0.7]$范围内时，我们的模型表现出色且稳定。即使在最差的设置下，我们的 C²DSR 仍优于表 2 中所示的其他基线方法。此外，我们发现，将 λ 设为较大的数值可以加快训练收敛。也就是说，$\lambda = 0.7$ 或许是在模型效果与效率之间较为均衡的选择。

对于超参数 L，图7(a)和7(b)分别展示了其在“食品”领域和“厨房”领域的预测性能，指标为NDCG@10和HR@10。如图所示，我们报告了 $L = \{0,1,2,3,4\}$条件下的推荐结果，其中 $L = 0$ 表示忽略图神经网络模块。总体而言，我们的模型在 $L = \{1,2\}$情况下稳步提升，在$L = \{3,4\}$情况下性能则有所下降。原因可能是深层图神经网络容易引发过平滑问题，从而限制模型捕获协同信号的能力。因此，选择较小的 L 值是合理的。

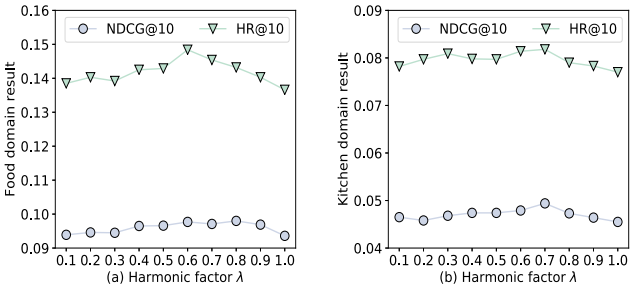


图 6：调和因子的结果 λ。

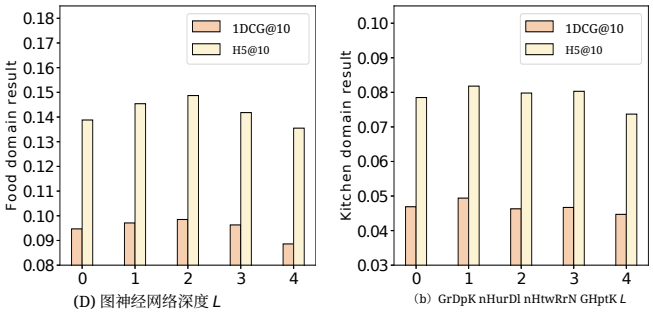


图7：GNN深度的影响 L。

5 相关工作

对比学习 提供了一种有前景的范式，可通过计算输入变量之间的互信息（MI）来衡量它们的依赖关系。近年来，一些经典研究提出将对比学习应用于计算机视觉、神经语言处理和图数据，例如DIM [13], 、CPC [39] 和DGI [40]。DIM设计了一种对比目标，以最大化局部图像表示与全局图像表示之间的互信息。CPC面向结构化序列数据，旨在最大化部分历史表示与其汇总的未来表示之间的互信息。DGI进一步将对比学习扩展到非结构化图数据，旨在最大化局部子图表示与相应全局图表示之间的互信息。近期，这一思路也被应用于序列推荐，例如 S^3-Rec [44] 提出了对比目标，以最大化不同形式或粒度下物品上下文信息的互信息。在本研究中，我们设计了一种新颖的对比信息最大化目标，以最大化CDSR中单域表示与跨域表示之间的互信息。

跨域推荐是缓解推荐系统中数据稀疏性问题的一种有效技术。典型的跨域推荐模型由单域推荐模型扩展而来，例如 CMF [33], 和 M^3Rec [1]。这些方法利用其他辅助领域中的交互来补充用户行为，从而在目标域中做出更好的推荐。近年来，迁移学习的理念催生了许多研究工作，例如 CoNet [14],和 BiTGCF [25]。这些方法首先利用两个基础神经网络分别对源域和目标域中的用户—物品交互进行建模，然后设计不同的迁移模块将它们融合。在此基础上，最新的研究致力于挖掘并迁移跨领域共享的信息，例如 DisenCDR [2] 和 CDRIB [4]。

序列推荐通过最新的历史交互序列对用户动态偏好进行建模，以预测未来物品。序列推荐的开创性研究通常基于马尔可夫链假设 [8, 9, 32]。这些方法学习物品与物品之间的共现关系，并利用该关系，根据用户最近交互过的物品预测下一个物品。近年来，随着.....浪潮的兴起
神经网络领域已提出多种方法来建模序列推荐（SR），例如循环网络（GRU4Rec [12],、HRNN [28]）、卷积神经网络（Caser [38]）、注意力网络（SAS-Rec [16], 、NARM [22]）和图网络（SR-GNN [43]）。

跨域序列推荐 旨在为物品分属多个领域的序列推荐任务提供更好的推荐。开创性工作 π-Net [27] 和 PSJNet [36],设计了精巧的门控机制，以迁移单域信息。Zhuang等人 [45] 提出了一种跨域新颖性寻求算法，用于更好地建模个体在不同领域间进行知识迁移的倾向。此外，一些研究构建了不同领域物品之间的交互图（或知识图谱），以引导跨域信息迁移，例如 DA-GCN [7] 和 MIFN [26]。在工业界，SEMI [20] 和 RecGURU [21] 被提出用于跨域短视频推荐（例如淘宝视频和腾讯视频），方法是利用额外的多模态信息（例如文本和关键帧信息）或采用对抗学习。与这些方法相比，我们的 C^2DSR 在设计上有以下重要区别：（1）我们同时考虑单域和跨域用户偏好；（2）我们设计了一种新颖的对比信息最大化目标，以捕捉跨域相关性。

6 结论

本文提出了一种用于跨域序列推荐的新模型 C^2DSR，该模型同时利用序列内和序列间的物品关系，并联合学习单域和跨域的用户偏好。具体而言，我们的方法包含一个图结构与注意力编码器，用于同时利用序列内和序列间的物品关系；此外，还采用两个序列目标和一个对比目标，以联合学习并增强单域和跨域的用户偏好。此外，我们发布了重新划分的数据集，以进行公平比较。实证结果表明，C^2DSR 的效果显著，达到了新的最先进性能。此外，我们还详细分析了模型组件和对比目标的有效性。未来，我们将探索该模型在多域设置和连续时间空间中的应用。

致谢

我们非常感谢 Jie Yu 在早期稿件讨论中给予的帮助，也感谢匿名审稿人提出的建设性意见。本研究得到国家重点研发计划（项目编号：2021YFB3100600）和中国科学院战略性先导科技专项的资助,

（项目编号：XDC02040400），并得到中国科学院青年创新促进会（项目编号：2021153）的资助。

参考文献

[1] Jiangxia Cao、Xin Cong、Tingwen Liu 和 Bin Wang。2022年。多市场推荐中的物品相似度挖掘。发表于 ACM信息检索研究与发展国际会议（SIGIR）。[2] Jiangxia Cao、Xixun Lin、Xin Cong、Jing Ya、Tingwen Liu 和 Bin Wang。2022年。DisenCDR：学习用于跨域推荐的解耦表示。发表于 ACM信息检索研究与发展国际会议（SIGIR）。[3] Jiangxia Cao、Xixun Lin、Shu Guo、Luchen Liu、Tingwen Liu 和 Bin Wang。2021年。通过互信息最大化进行二部图嵌入。发表于 ACM网络搜索与数据挖掘国际会议（WSDM）。[4] Jiangxia Cao、Jiawei Sheng、Xin Cong、Tingwen Liu 和 Bin Wang。2022年。通过变分信息瓶颈为冷启动用户提供跨域推荐。发表于 IEEE数据工程国际会议（ICDE）。[5] Jacob Devlin、Ming-Wei Chang、Kenton Lee 和 Kristina Toutanova。2019年。BERT：用于语言理解的深度双向 Transformer 预训练。发表于北美计算语言学协会年会（NAACL）。[6] Ian J. Goodfellow、Jean Pouget-Abadie、Mehdi Mirza、Bing Xu、David Warde-Farley、Sherjil Ozair、Aaron C. Courville 和 Yoshua Bengio。2014年。生成对抗网络。发表于神经信息处理系统年会（NeurIPS）。[7] Lei Guo、Li Tang、Tong Chen、Lei Zhu、Quoc Viet Hung Nguyen 和 Hongzhi Yin。2021年。DA-GCN：用于共享账户跨域序列推荐的领域感知注意力图卷积网络。发表于国际人工智能联合会议（IJCAI）。[8] Ruining He、Wang-Cheng Kang 和 Julian McAuley。2017年。基于平移的推荐。（2017年）。[9] Ruining He 和 Julian McAuley。2016年。将相似度模型与马尔可夫链融合，用于稀疏序列推荐。发表于 IEEE数据挖掘国际会议（ICDM）。[10] Xiangnan He、Kuan Deng、Xiang Wang、Yan Li、Yongdong Zhang 和 Meng Wang。2020年。Lightgcn：简化并增强用于推荐的图卷积网络。发表于 ACM信息检索研究与发展国际会议（SIGIR）。[11] Xiangnan He、Lizi Liao、Hanwang Zhang、Liqiang Nie、Xia Hu 和 Tat-Seng Chua。2017年。神经协同过滤。发表于万维网会议（WWW）。[12] Balázs Hidasi、Alexandros Karatzoglou、Linas Baltrunas 和 Domonkos Tikk。2015年。基于循环神经网络的会话推荐。发表于学习表征国际会议（ICLR）。[13] R Devon Hjelm、Alex Fedorov、Samuel Lavoie-Marchildon、Karan Grewal、Phil Bachman、Adam Trischler 和 Yoshua Bengio。2019年。通过互信息估计与最大化学习深度表示。发表于学习表征国际会议（ICLR）。[14] Guangneng Hu、Yu Zhang 和 Qiang Yang。2018年。Conet：用于跨域推荐的协同跨网络。发表于 ACM信息与知识管理国际会议（CIKM）。[15] Kalervo Järvelin 和 Jaana Kekäläinen。2002年。基于累积增益的检索技术评估。ACM信息系统汇刊（TOIS）（2002年）。[16] Wang-Cheng Kang 和 Julian McAuley。2018年。自注意力序列推荐。发表于 IEEE数据挖掘国际会议（ICDM）。[17] P. Diederik Kingma 和 Lei Jimmy Ba。2015年。Adam：一种随机优化方法。发表于学习表征国际会议（ICLR）。[18] Thomas N. Kipf 和 Max Welling。2017年。基于图卷积网络的半监督分类。发表于学习表征国际会议（ICLR）。[19] Walid Krichene 和 Steffen Rendle。2020年。关于物品推荐的采样指标。发表于 ACM知识发现与数据挖掘会议（KDD）。[20] Chenyi Lei、Yong Liu、Lingzi Zhang、Guoxin Wang、Haihong Tang、Houqiang Li 和 Chunyan Miao。2021年。SEMI：用于电子商务短视频推荐的序列式多模态信息传递网络。发表于 ACM知识发现与数据挖掘会议（KDD）。[21] Chenglin Li、Mingjun Zhao、Huanming Zhang、Chenyun Yu、Lei Cheng、Guoqiang Shu、Beibei Kong 和 Di Niu。2022年。RecGURU：通过对抗学习获得用于跨域推荐的泛化用户表示。发表于 ACM网络搜索与数据挖掘国际会议（WSDM）。[22] J. Li、Pengjie Ren、Zhumin Chen、Zhaochun Ren、Tao Lian 和 Jun Ma。2017年。神经注意力会话推荐。在 ACM信息与知识管理国际会议（CIKM）中。[23] Jiacheng Li、Yujie Wang 和 Julian McAuley。2020年。时间间隔感知的序列推荐自注意力机制。在 ACM网络搜索与数据挖掘会议（WSDM）中。[24] Ralph Linsker。1988年。感知网络中的自组织。《Computer》（1988年）。[25] Meng Liu、Jianjun Li、Guohui Li 和 Peng Pan。2020年。通过双向迁移图协同过滤网络实现跨域推荐。在 ACM信息与知识管理国际会议（CIKM）中。[26] Muyang Ma、Pengjie Ren、Zhumin Chen、Zhaochun Ren、Lifan Zhao、Jun Ma 和 M. de Rijke。2022年。面向跨域序列推荐的混合信息流。《ACM数据知识发现汇刊》（TKDD）（2022年）。[27] Muyang Ma、Pengjie Ren、Yujie Lin、Zhumin Chen、Jun Ma 和 M. de Rijke。2019年。π-Net：面向共享账户跨域序列推荐的并行信息共享网络。在 ACM信息检索研究与发展国际会议（SIGIR）中。[28] Massimo Quadrana、Alexandros Karatzoglou、Balázs Hidasi 和 Paolo Cremonesi。2017年。利用层次循环神经网络实现个性化会话推荐。在 ACM推荐系统会议（RecSys）中。[29] Pengjie Ren、Zhumin Chen、Jing Li、Zhaochun Ren、Jun Ma 和 Maarten De Rijke。2019年。Repeatnet：面向会话推荐的重复感知神经推荐机。在 AAAI人工智能会议（AAAI）中。[30] Steffen Rendle、Christoph Freudenthaler、Zeno Gantner 和 Lars Schmidt-Thieme。2009年。BPR：基于隐式反馈的贝叶斯个性化排序。人工智能不确定性国际会议（UAI）（2009年）。[31] Badrul Munir Sarwar、George Karypis、Joseph A. Konstan 和 John Riedl。2001年。基于项目的协同过滤推荐算法。在万维网会议（WWW）中。[32] Guy Shani、David Heckerman 和 Ronen I. Brafman。2002年。基于MDP的推荐系统。《机器学习研究杂志》（JMLR）（2002年）。[33] Ajit P Singh 和 Geoffrey J Gordon。2008年。通过集体矩阵分解进行关系学习。在 ACM知识发现与数据挖掘会议（KDD）中。[34] Jake Snell、Kevin Swersky 和 Richard S. Zemel。2017年。面向小样本学习的原型网络。在神经信息处理系统年会（NeurIPS）中。[35] Fei Sun、Jun Liu、Jian Wu、Changhua Pei、Xiao Lin、Wenwu Ou 和 Peng Jiang。2019年。BERT4Rec：基于 Transformer 双向编码器表示的序列推荐。在 ACM信息与知识管理国际会议（CIKM）中。[36] Wenchao Sun、Pengjie Ren、Yujie Lin、Muyang Ma、Zhumin Chen、Zhaochun Ren、Jun Ma 和 Maarten de Rijke。2022年。面向共享账户跨域序列推荐的并行分裂合并网络。IEEE知识与数据工程汇刊（TKDE）（2022年）。[37] Flood Sung、Yongxin Yang、Li Zhang、Tao Xiang、Philip HS Torr 和 Timothy M Hospedales。2018 年。学习比较：面向小样本学习的关系网络。在 IEEE计算机视觉与模式识别会议（CVPR）中。[38] Jiaxi Tang 和 Ke Wang。2018年。通过卷积序列嵌入实现个性化Top-N序列推荐。在 ACM网络搜索与数据挖掘会议（WSDM）中。[39] Aäron van den Oord、Yazhe Li 和 Oriol Vinyals。2018年。利用对比预测编码进行表示学习。arXiv（2018年）。[40] Petar Veličković、William Fedus、William L Hamilton、Pietro Liò、Yoshua Bengio 和 R Devon Hjelm。2019年。深度图信息最大化。在学习表征国际会议（ICLR）中。[41] Ellen M. Voorhees。1999年。TREC-8问答赛道报告。在文本检索会议（TREC）中。[42] Felix Wu、Amauri Souza、Tianyi Zhang、Christopher Fifty、Tao Yu 和 Kilian Weinberger。2019年。简化图卷积网络。在国际机器学习会议（ICML）中。[43] Shu Wu、Yuyuan Tang、Yanqiao Zhu、Liang Wang、Xing Xie 和 Tieniu Tan。2019年。基于图神经网络的会话推荐。在 AAAI人工智能会议（AAAI）中。[44] Kun Zhou、Haibo Wang、Wayne Xin Zhao、Yutao Zhu、Sirui Wang、Fuzheng Zhang、Zhong yuan Wang 和 Ji-Rong Wen。2020年。S3-Rec：利用互信息最大化进行序列推荐的自监督学习。在 ACM信息与知识管理国际会议（CIKM）中。[45] Fuzhen Zhuang、Yingmin Zhou、Haochao Ying、Fuzheng Zhang、Xiang Ao、Xing Xie、Qing He 和 Hui Xiong。2020年。通过跨域新颖性寻求特质挖掘进行序列推荐。《计算机科学与技术》（JCST）（2020年）。