S²CDR：面向跨域推荐的平滑-锐化过程模型

李晓东
信息工程研究所，
中国科学院
网络空间安全学院，中国科学院大学†
中国北京
lixiaodong@iie.ac.cn

Juwei Yue
信息工程研究所，
中国科学院
网络空间安全学院，中国科学院大学
中国北京
yuejuwei@iie.ac.cn

Xinghua Zhang 阿里巴巴集团
中国北京
zxh.zhangxinghua@gmail.com

Jiawei Sheng
信息工程研究所，
中国科学院
中国北京
shengjiawei@iie.ac.cn

Wenyuan Zhang
信息工程研究所，
中国科学院
网络空间安全学院，中国科学院大学
中国北京
zhangwenyuan@iie.ac.cn

Taoyu Su
信息工程研究所，
中国科学院
中国北京
sutaoyu@iie.ac.cn

Zefeng Zhang 中国科学院信息工程研究所网络空间安全学院，中国科学院大学，中国北京
zhangzefeng@iie.ac.cn

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

arXiv:2603.02725v1 [cs.IR] 3 Mar 2026

摘要

用户冷启动问题一直是推荐系统面临的挑战。幸运的是，跨域推荐（CDR）已成为解决用户冷启动问题的有效方法，而近期开发的扩散模型（DM）展现出卓越的性能。然而，这些基于扩散模型的跨域推荐方法侧重于处理用户-物品交互，却忽视了源域和目标域中物品之间的相关性。同时，扩散模型前向过程中添加的高斯噪声会损害用户的个性化偏好，导致难以在不同领域间迁移用户偏好。为此，我们提出一种面向冷启动用户的新型平滑-锐化过程模型，用于跨域推荐范式，称为**S²跨域推荐**，其特点是采用破坏-恢复架构，并通过常微分方程（ODE）求解。具体而言，平滑过程逐步破坏由两个域导出的原始用户-物品/物品-物品交互矩阵，将其转化为以无噪声方式平滑后的偏好信号；而锐化过程则迭代锐化偏好信号，以恢复冷启动用户未知的交互。其中，对于平滑过程，我们在物品-物品相似度图上引入热方程，以更好地捕捉跨域物品间的相关性，并进一步依据图信号处理（GSP）理论，构建专门设计的低通滤波器，以滤除高频噪声信息，从而捕捉用户的内在偏好。在三个真实世界跨域推荐场景上的大量实验表明，我们的 S²CDR 无需训练即可显著优于以往的当前最优方法。

CCS 概念

• **信息系统** → **推荐系统**。

关键词

跨域推荐、冷启动推荐、协同过滤

ACM 参考格式：
李晓东、Juwei Yue、Xinghua Zhang、Jiawei Sheng、Wenyuan Zhang、Taoyu Su、Zefeng Zhang 和 Tingwen Liu。2026 年。S²CDR：面向跨域推荐的平滑-锐化过程模型。载于 *ACM Web Conference 2026* 论文集（*WWW '26*），*2026*年*4*月*13*日至*17*日，阿拉伯联合酋长国迪拜。ACM，纽约，美国纽约州，11 页。https://doi.org/10.1145/ 3774904.3792189

*通讯作者。†中国科学院大学。

本作品采用知识共享署名 4.0 国际许可协议授权。万维网大会 '26，阿拉伯联合酋长国迪拜© 2026 版权所有归作品所有者/作者所有。ACM ISBN 979-8-4007-2307-0/2026/04 https://doi.org/10.1145/3774904.3792189

1 引言

推荐系统（RS） [9, 26, 35] 已广泛应用于各种在线平台，例如阿里巴巴（电子商务）和 TikTok（在线视频），由此在电子商务网站的不同类别以及在线视频的不同媒体形式中产生了多种用户交互。因此，如何制定有效策略，为各个领域中新近加入的（冷启动）用户提供推荐，已成为推荐系统面临的一项关键挑战。

为缓解冷启动问题 [32, 39], 跨域推荐（***CDR***）[17, 19, 20, 23] 近年来受到了广泛关注，其目标是探索并利用相关领域中的有价值知识，为另一领域的冷启动用户带来理想的推荐性能。跨域推荐方法的一个常见思路是利用重叠用户连接源域和目标域，从而为仅在一个领域中有交互的冷启动（非重叠）用户提供推荐。遵循上述思路，传统的跨域推荐方法 [14, 23, 25]大多采用基于映射的范式，分别对两个领域中的用户/物品表示进行编码，然后学习映射函数，以实现用户偏好在领域间的迁移。此外，一些基于元学习的方法 [17, 31, 45] 进一步采用元学习范式，将每位用户的跨域推荐视为一项独立任务，并为每位用户学习映射函数，以实现个性化偏好迁移。

扩散模型（扩散模型） [10] 凭借其表示重建能力，在推荐系统领域 [13, 24, 34, 40, 41] 取得了显著成功。最近，DMCDR [19] 率先将扩散模型应用于跨域推荐：它在前向过程中通过添加高斯噪声逐步破坏用户表示，然后在源域用户-物品交互所得到的用户偏好引导下，迭代生成目标域中的个性化用户表示。然而，基于扩散模型的范式在跨域推荐任务中存在以下两个局限：（1）**缺乏物品相关性**：扩散模型强调用户-物品交互，却忽略了捕捉源域和目标域之间的物品相关性，而该相关性同样是偏好迁移的关键桥梁。（2）**外部噪声的危害**：前向过程中添加的高斯噪声会损害用户内在的个性化偏好，从而导致跨领域迁移次优的用户偏好。

为解决上述问题，本文提出**S²跨域推荐**，这是一种面向冷启动用户的新型***S***平滑-***S***跨域推荐的平滑-锐化过程模型跨域推荐，采用破坏-恢复架构。具体而言，借助图信号处理（GSP） [21, 29, 36, 38]，平滑过程通过专门设计的图滤波器，以无噪声的方式逐步平滑来自两个域的用户/项目信息，包括用户-项目和物品-物品交互信号。其中，我们在物品-物品相似度图上计算热方程，以捕捉跨域物品间的相关性，并进一步构建有效的低通滤波器，滤除通常属于噪声的高频信息 [21, 29]。随后，锐化过程 迭代优化并锐化偏好信号，以描述用户的个性化偏好，从而恢复冷启动用户的潜在交互。

为了运行我们的平滑-锐化过程模型，我们进一步引入常微分方程（ODE） [3, 5]，通过以连续方式求解平滑与锐化函数，实现更有效、更高效的跨域偏好迁移，自然地刻画用户用于迁移的内在偏好，并为我们的免训练方法提供支持。大量实验表明，在三个真实世界跨域推荐场景中，我们的 S²CDR 优于以往的最先进方法。同时，作为一种非参数方法，我们的 S²CDR 展现出很高的计算效率。我们的主要贡献总结如下：

- 我们为跨域推荐提出了一种损坏-恢复范式，该范式在跨域偏好迁移中发挥物品相关性的桥接效应，同时保留用户的内在偏好特征。

- 我们提出一种新型平滑-锐化过程模型 S²跨域推荐，面向冷启动用户进行跨域推荐。其中，平滑过程借助专门设计的图滤波器平滑用户-项目/物品-物品交互信号，以捕捉用户偏好；锐化过程则锐化偏好信号，以恢复冷启动用户的未知交互。

- 我们在三个真实世界的跨域推荐场景中进行了大量实验，以证明 S²CDR 相较于以往当前最优方法的有效性和效率。尽管 S²CDR 无需任何训练，但在六组跨域对上，HR 和 NDCG 指标的平均相对提升仍分别达到 7.07% 和 7.42%。

2 预备知识

本节回顾图信号处理（GSP）和常微分方程（ODE）的背景知识，并定义跨域推荐问题设定。我们还将回顾扩散模型（DM），并在**附录 A.1**中对 DMCDR 与 S²CDR 进行正式比较。

2.1 图信号处理

本小节将介绍图信号处理（GSP）的基本概念 [6, 27], , 包括图信号、图滤波器和图卷积。

2.1.1 图信号。 给定一个加权无向图 $\mathcal{G} = (\mathcal{V}, \mathcal{E})$，其中 $\mathcal{V} = \{v_1, v_2, \ldots, v_n\}$ 表示包含 n 个节点（例如，用户或物品）的顶点集，$\mathcal{E}$ 是边集（例如，用户-物品交互）。图 $\mathcal{G}$ 导出邻接矩阵 $\boldsymbol{A} \in \mathbb{R}^{n \times n}$；若节点 v_i 与节点 v_j 之间存在一条边，则 $\boldsymbol{A}_{i,j} = 1$，否则 $\boldsymbol{A}_{i,j} = 0$。图信号本质上是一个映射 $f: \mathcal{V} \to \mathbb{R}$，记作 $\boldsymbol{x} = [x_1, x_2, \ldots, x_n]^\top$，其中 x_i 表示节点 v_i 上的信号强度。

图拉普拉斯矩阵是谱图论中的核心概念 [30]，可定义为 $\boldsymbol{L} = \boldsymbol{D} - \boldsymbol{A}$，其中 $\boldsymbol{D} = diag(\boldsymbol{A}\cdot\boldsymbol{1})$ 为度矩阵，$\boldsymbol{D}_{i,i} = \sum_j \boldsymbol{A}_{i,j}$。此外，归一化˜ ˜图拉普拉斯矩阵可定义为 $\boldsymbol{L} = \boldsymbol{I} - \boldsymbol{A}$，其中 $\boldsymbol{I}$ 表示单位矩阵，且 $\tilde{\boldsymbol{A}} = \boldsymbol{D}^{-1/2}\boldsymbol{A}\boldsymbol{D}^{-1/2}$。

2.1.2 图滤波器与图卷积。 由于图拉普拉斯矩阵是实对称矩阵，因此可将其分解为 $\boldsymbol{L} = \boldsymbol{U}\boldsymbol{\Lambda}\boldsymbol{U}^\top$，其中 $\boldsymbol{\Lambda} = \lambda_1\ \lambda_2\ \lambda_n \quad \lambda_1 \le \lambda_2 \le \le \lambda_n \quad \boldsymbol{U} = \boldsymbol{u}_1\ \boldsymbol{u}_2\ \ldots\ \boldsymbol{u}_n$ $diag(„,\ldots,)$ 为特征值矩阵，其特征值为 $\cdots$，而 $(„,)$ 为特征向量矩阵，其中 $\boldsymbol{u_i} \in \mathbb{R}^n$ 是特征值 λ_i 对应的特征向量。

我们可以将特征向量矩阵 $\boldsymbol{U}$ 视为图傅里叶变换（GFT）的基。具体而言，给定图信号 $\boldsymbol{x} \in \mathbb{R}_n$，GFT 定义为 $\hat{\boldsymbol{x}} = \boldsymbol{U}^\top\boldsymbol{x}$，逆变换为 $\boldsymbol{x} = \boldsymbol{U}\hat{\boldsymbol{x}}$。因此，图滤波器 $\mathcal{H}(\boldsymbol{L})$ 定义如下：

$$\mathcal{H}(\boldsymbol{L}) = \boldsymbol{U}\,diag(h(\lambda_1), h(\lambda_2), \ldots, h(\lambda_n))\boldsymbol{U}^\top, \tag{1}$$

其中，$h(\cdot)$ 是定义在特征值上的滤波器。给定输入信号 $\boldsymbol{x}$ 和滤波器 $\mathcal{H}(\boldsymbol{L})$，图卷积定义如下：

$$\boldsymbol{y} = \mathcal{H}(\boldsymbol{L})\boldsymbol{x} = \boldsymbol{U}\,diag(h(\lambda_1), h(\lambda_2), \ldots, h(\lambda_n))\boldsymbol{U}^\top\boldsymbol{x}, \tag{2}$$

其中，图信号 $\boldsymbol{x}$ 通常是协同过滤中的用户-项目观测评分 [21, 29],，或用户/项目的初始嵌入 [8, 35]。总而言之，原始图信号 $\boldsymbol{x}$ 首先通过图傅里叶变换基 $\boldsymbol{U}^\top$ 从空间域变换到谱域，然后由滤波器 $h(\cdot)$ 处理谱域信号，最后通过逆图傅里叶变换基 $\boldsymbol{U}$ 将信号变换回空间域。

2.2 常微分方程

式 (1) 中的图滤波器 $\mathcal{H}(\boldsymbol{L})$ 采用离散时间方式处理矩阵 $\boldsymbol{A}$。然而，为了捕捉图结构的连续动力学，我们将目光投向采用连续时间方式的常微分方程（ODE） [3, 5]。

给定时间 $t = 0$ 的初始值 $\boldsymbol{x}_0$，常微分方程通过求解以下黎曼积分问题 [3]，计算从 $\boldsymbol{x}_0$ 到 $\boldsymbol{x}_T$ 的结果：

$$\boldsymbol{x}_T = \boldsymbol{x}_0 + \int_0^T f(\boldsymbol{x}_t)dt, \tag{3}$$

其中，f：$\mathbb{R}^{dim(\boldsymbol{x})} \to \mathbb{R}^{dim(\boldsymbol{x})}$ 是一个常微分方程函数[1]，用于近似 $\boldsymbol{x}$ 的时间导数，即，$\frac{d\boldsymbol{x}_t}{dt}$。

由于通常难以求得 $\boldsymbol{x}_T$的解析解，我们一般依赖现有的常微分方程求解器，例如显式欧拉法、Dormand–Prince（DOPRI）方法、龙格-库塔法等 [7]。具体而言，常微分方程求解器将时间变量 t 离散化，并把积分转化为一系列加法步骤。显式欧拉法可写为如下形式：

$$\boldsymbol{x}_{t+s} = \boldsymbol{x}_t + s \cdot f(\boldsymbol{x}_t), \tag{4}$$

其中 s 是设定的步长，通常小于1。

其他常微分方程求解器采用更复杂的方法，根据 $\boldsymbol{x}_t$更新 $\boldsymbol{x}_{t+s}$。例如，四阶龙格-库塔（RK4）方法可表示如下：

$$\boldsymbol{x}_{t+s} = \boldsymbol{x}_t + \frac{s}{6}(f_1 + 2f_2 + 2f_3 + f_4), \tag{5}$$

其中 $f_1 = f(\boldsymbol{x}_t)$ $f_2 = f(\boldsymbol{x}_t + \frac{s}{2}f_1)$ $f_3 = f(\boldsymbol{x}_t + \frac{s}{2}f_2)$ $f_4 = f(\boldsymbol{x}_t + sf_3)$。

同样值得注意的是隐式Adams-Moulto方法，其可推导如下：

$$\boldsymbol{x}_{t+s} = \boldsymbol{x}_t + \frac{s}{24}(9f_1 + 19f_2 - 5f_3 + f_4), \tag{6}$$

其中 $f_1 = f(\boldsymbol{x}_{t+s})$、$f_2 = f(\boldsymbol{x}_t)$、$f_3 = f(\boldsymbol{x}_{t-s})$ 和 $f_4 = f(\boldsymbol{x}_{t-2s})$。隐式方法与上述显式方法不同，因为它利用了过去的多步历史（即，f_3 和 f_4），从而能够学习到更稳健的导数项。

为求解上述积分问题，我们需要迭代固定步长常微分方程求解器 T/s 次，每次迭代都会将 $\boldsymbol{x}_t$ 更新为 $\boldsymbol{x}_{t+s}$。在实验中，我们考虑了所有这些常微分方程求解器。

2.3 问题设定

我们假设存在两个域，即，源域 $\mathcal{D}^s$ 和目标域 $\mathcal{D}^t$。形式上，用户-物品交互数据可表示为 $\mathcal{D}^s = \{\mathcal{U}^s, \mathcal{V}^s, \mathcal{Y}^s\}$ 和 $\mathcal{D}^t = \{\mathcal{U}^t, \mathcal{V}^t, \mathcal{Y}^t\}$，其中 $\mathcal{U}$、$\mathcal{V}$和 $\mathcal{Y}$分别表示用户集、物品集和评分。

[1]在神经常微分方程（NODE） [3]中，常微分方程函数 f 可以通过神经网络学习。与此相反，本文利用平滑-锐化函数来近似 f。

我们将源域和目标域中的用户-物品交互矩阵分别定义为 $\boldsymbol{R}^s \in \mathbb{R}^{|\mathcal{U}^s|\times|\mathcal{V}^s|}$和$\boldsymbol{R}^t \in \mathbb{R}^{|\mathcal{U}^t|\times|\mathcal{V}^t|}$，其中 $\boldsymbol{R}_{i,\ j} = 1$表示用户 u_i 与物品 v_j发生过交互，否则 $\boldsymbol{R}_{i,\ j} = 0$。为简化问题设定，我们假设两个域均不包含其他辅助信息。此外，我们将两个域中都存在的重叠用户集合定义为 $\mathcal{U}^o = \mathcal{U}^s \cap \mathcal{U}^t$。因此，仅存在于源域中的冷启动用户可表示为 $\mathcal{U}^{s\backslash o} = \mathcal{U}^s \setminus \mathcal{U}^o$，而仅存在于目标域中的冷启动用户可表示为 $\mathcal{U}^{t\backslash o} = \mathcal{U}^t \setminus \mathcal{U}^o$。

给定源域和目标域中重叠用户及冷启动（非重叠）用户的用户-物品交互矩阵（例如，$\boldsymbol{R}^s$ 和 $\boldsymbol{R}^t$），我们的跨域推荐目标是利用重叠用户的跨域交互模式，预测冷启动用户可能在源域或目标域中交互的项目。为实现上述目标，我们遵循先前的方法 [19, 23, 25, 45],，采用统一用户-物品交互矩阵 $\boldsymbol{R}^{st} \in \mathbb{R}^{(|\mathcal{U}^o|+|\mathcal{U}^s{}_{\backslash o}|+|\mathcal{U}^{t\backslash o}|)\times(|\mathcal{V}^s|+|\mathcal{V}^t|)}$，利用重叠用户连接源域和目标域，如下所示：

$$\boldsymbol{R}^{st} = \begin{bmatrix} \mathbb{R}^{|\mathcal{U}^{s\backslash o}|\times|\mathcal{V}^s|} & \mathbb{R}^{|\mathcal{U}^{s\backslash o}|\times|\mathcal{V}^t|} \\ \mathbb{R}^{|\mathcal{U}^o|\times|\mathcal{V}^s|} & \mathbb{R}^{|\mathcal{U}^o|\times|\mathcal{V}^t|} \\ \mathbb{R}^{|\mathcal{U}^{t\backslash o}|\times|\mathcal{V}^s|} & \mathbb{R}^{|\mathcal{U}^{t\backslash o}|\times|\mathcal{V}^t|} \end{bmatrix}, \tag{7}$$

其中，$\mathbb{R}^{|\mathcal{U}^{s\backslash o}|\times|\mathcal{V}^s|}$、$\mathbb{R}^{|\mathcal{U}^o|\times|\mathcal{V}^s|}$、$\mathbb{R}^{|\mathcal{U}^o|\times|\mathcal{V}^t|}$和 $\mathbb{R}^{|\mathcal{U}^{t\backslash o}|\times|\mathcal{V}^t|}$为观测到的用户-物品交互矩阵。同时，$\mathbb{R}^{|\mathcal{U}^{s\backslash o}|\times|\mathcal{V}^t|}$和$\mathbb{R}^{|\mathcal{U}^{t\backslash o}|\times|\mathcal{V}^s|}$为包含冷启动用户的全零矩阵，将由我们的模型进行推断。

为确保不同度数的节点（用户/物品）产生相同的影响，我们将归一化交互矩阵定义为 $\tilde{\boldsymbol{R}}^{st} = \boldsymbol{D}_U^{-1/2}\boldsymbol{R}^{st}\boldsymbol{D}_I^{-1/2}$，其中 $\boldsymbol{D}_U^{-1/2} = \text{对角矩阵}(\boldsymbol{R}^{st}\cdot\boldsymbol{1})$ 和 $\boldsymbol{D}_I^{-1/2} = \text{对角矩阵}(\boldsymbol{1}^\top\boldsymbol{R}^{st})$ 是 $\boldsymbol{R}^{st}$ 的度矩阵。我们进一步将物品-物品相似度图的归一化邻接矩阵定义为 $\tilde{\boldsymbol{P}} = \tilde{\boldsymbol{R}}^{st\top}\tilde{\boldsymbol{R}}^{st}$。本文使用的符号总结于**附录 A.2**。

3 方法

本节介绍我们提出的 S²跨域推荐，该方法实现了平滑-锐化原理，如图1所示。我们的 S²跨域推荐主要由两部分组成，即，平滑过程 和锐化过程。平滑过程旨在以无噪声的方式将原始用户-物品交互矩阵转化为平滑后的偏好信号。至于恢复阶段，锐化过程会迭代地细化并锐化偏好信号，为两个域中的冷启动用户生成新的交互。

3.1 概述

给定用户-物品交互矩阵 $\boldsymbol{R}^{st}$ （如公式（7）所述），我们首先对 $\boldsymbol{R}^{st}$ 应用连续平滑过程，得到其受扰动后的矩阵 $\boldsymbol{B}_{T_b}$，其中包含平滑后的偏好信号。随后，我们对 $\boldsymbol{B}_{T_b}$引入连续锐化过程，得到其细化并锐化后的矩阵 $\boldsymbol{H}_{T_h}$，从而揭示冷启动用户的隐藏交互。

平滑过程分析。平滑过程是协同过滤的核心，并已在许多基于GSP的方法中作为图卷积滤波器得到广泛研究 [15, 21, 29, 36, 38]。在这些传统方法中，经过这一过程后，系统会向用户推荐候选物品。

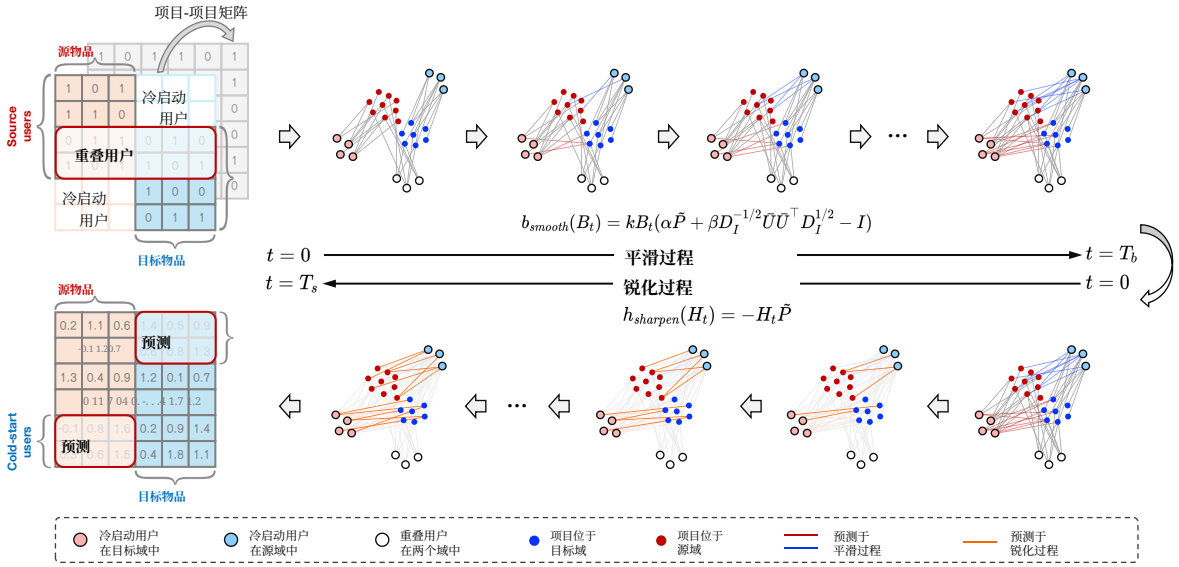

图1：S²CDR 的整体框架。平滑过程旨在以无噪声的方式，逐步将原始用户-物品/物品-物品交互信号转化为平滑后的偏好信号；而锐化过程则通过迭代细化并锐化偏好信号，为冷启动用户恢复未知交互。

锐化过程分析。锐化过程用于优化并锐化通过平滑过程获得的偏好信号。更进一步地说，锐化过程旨在描述用户的个性化偏好。与扩散模型的反向过程类似 [10],，经过这一过程后，会为冷启动用户预测未知用户-物品交互。

我们还要进一步强调，S²CDR 是一种计算效率高的非参数方法。在平滑-锐化过程中，我们的模型可以通过闭式解获得，而无需进行代价高昂的反向传播训练，因为 S²CDR 直接处理用户-物品/物品-物品交互矩阵，无需使用神经网络或用户/项目嵌入。

3.2 平滑过程

在跨域推荐中，我们的目标是预测冷启动用户可能在两个域中与之交互的潜在项目，这仅与用户-物品/物品-物品交互矩阵 $\boldsymbol{R}^{st}$/ $\tilde{\boldsymbol{P}}$ 相关。因此，我们认为，像扩散模型的前向过程那样向交互矩阵添加高斯噪声以破坏矩阵，既无效率，也无必要。此外，向交互矩阵添加过多噪声也会破坏对用户个性化偏好的建模。为此，我们提出一种专用于图信号的无噪声方式，反复执行平滑操作，直至交互矩阵达到稳态。

3.2.1 基于*ODE*的平滑过程。 平滑过程的总体思路是求解黎曼积分问题，以得到冷启动用户的平滑后的偏好信号，其可表述如下：

$$\boldsymbol{B}_{T_b} = \boldsymbol{B}_0 + \int_0^{T_b} b(\boldsymbol{B}_t)dt, \tag{8}$$

其中输入 $\boldsymbol{B}_0$ 为用户-物品交互矩阵 $\boldsymbol{R}^{st}$， T_b 为终止时间，且 b : $\mathbb{R}^{dim(B)} \to \mathbb{R}^{dim(B)}$ 为平滑函数，用于描述 $\boldsymbol{R}^{st}$的时间导数，即， $\frac{dB_t}{dt}$。

平滑过程的关键在于平滑函数 b的定义，下面我们将对此进行介绍。

3.2.2 使用热方程进行平滑。热方程描述了热扩散过程的规律，即牛顿冷却定律。这一概念已被用于图像合成 [11, 28]，通过模糊滤波器对图像进行模糊处理。受此启发，我们利用热˜方程捕获项目之间的相关性，具体如下：

$$b_{heat}(\boldsymbol{B}_t) = k\boldsymbol{B}_t(\tilde{\boldsymbol{P}} - \boldsymbol{I}), \tag{9}$$

其中， $k \in \mathbb{R}$ 是我们模型中的一个超参数，称为热容。平滑函数 b_{heat} 的定义类似于基于图信号处理的协同过滤方法 [21, 29, 38],中的线性滤波器，后者能够捕获源域和目标域之间的物品-物品相似度，并作为偏好迁移的关键桥梁。

3.2.3 使用理想低通滤波器进行平滑。平滑函 b_{heat} 数旨在捕获图中的低阶信息。受图卷积的启发，我们利用理想低通滤波器增强平滑函数的表征能力，以获得 $\boldsymbol{R}^{st}$ 中的高阶信息，具体如下：

$$b_{ideal}(\boldsymbol{B}_t) = \boldsymbol{B}_t(\boldsymbol{D}_I^{-1/2}\bar{\boldsymbol{U}}\bar{\boldsymbol{U}}^\top\boldsymbol{D}_I^{1/2} - \boldsymbol{I}), \tag{10}$$

其中， $\bar{\boldsymbol{U}}$ 是 $\boldsymbol{R}^{st}$的前 K 个奇异向量。平滑函 b_{heat} 滤除由高频信息主导的噪声信号，并保留由低频信息主导的用户内在偏好信号。

我们结合热方程 b_{heat} 和理想低通滤波器b_{ideal}，定义最终的平滑函数如下：

$$\begin{aligned} b_{smooth}(\boldsymbol{B}_t) &= \alpha \cdot b_{heat}(\boldsymbol{B}_t) + \beta \cdot b_{ideal}(\boldsymbol{B}_t) \\ &= k\boldsymbol{B}_t(\alpha\tilde{\boldsymbol{P}} + \beta\boldsymbol{D}_I^{-1/2}\bar{\boldsymbol{U}}\bar{\boldsymbol{U}}^\top\boldsymbol{D}_I^{1/2} - \boldsymbol{I}), \end{aligned} \tag{11}$$

其中，$k = 1$、α和 β是用于控制 b_{heat} 和 b_{ideal}强度的超参数。

因此，式（8）中的平滑过程可结合式（11）中的平滑函数 b_{smooth} 写为：

$$\boldsymbol{B}_{T_b} = \boldsymbol{B}_0 + \int_0^{T_b} b_{smooth}(\boldsymbol{B}_t)dt, \tag{12}$$

其中，$\boldsymbol{B}_{T_b}$是经过平滑处理、包含偏好信号的用户-物品交互矩阵；利用我们在第 2.2 节介绍的常微分方程求解器，可推导出式（12）。

3.3 锐化过程

作为平滑过程的对应过程，我们期望锐化过程能够迭代地细化并锐化平滑后的偏好信号，突出节点之间的差异，从而刻画用户的个性化偏好，并最终为两个域中的冷启动用户生成新的交互。锐化过程可表示如下：

$$\boldsymbol{H}_{T_h} = \boldsymbol{H}_0 + \int_0^{T_h} h(\boldsymbol{H}_t)dt, \tag{13}$$

其中，输入矩阵 $\boldsymbol{H}_0 = \boldsymbol{B}_{T_b}$是式 (12) 中平滑过程的输出，$T_h$ 是终止时间，而 h：$\mathbb{R}^{dim(H)} \to \mathbb{R}^{dim(H)}$ 是用于近似 $\frac{d\boldsymbol{H}_t}{dt}$的锐化函数。

为了突出与邻居之间的差异，从而捕捉用户的个性化偏好，我们将锐化函数定义如下：

$$h_{sharpen}(\boldsymbol{H}_t) = -\boldsymbol{H}_t\tilde{\boldsymbol{P}}, \tag{14}$$

其中，添加负号是为了细化并锐化平滑后的偏好信号。因此，最终的锐化过程可表示如下：

$$\hat{\boldsymbol{R}}^{st} = \boldsymbol{H}_0 + \int_0^{T_h} h_{sharpen}(\boldsymbol{H}_t)dt, \tag{15}$$

其中，$\boldsymbol{H}_0 = \boldsymbol{B}_{T_b}$，而 $\hat{}\boldsymbol{R}^{st}$ 是锐化后的用户-物品交互矩阵，其中包含用户的个性化偏好，可用于推断 $\mathbb{R}^{|\mathcal{U}^{s\setminus o}|\times|\mathcal{V}^t|}$和 $\mathbb{R}^{|\mathcal{U}^{t\setminus o}|\times|\mathcal{V}^s|}$中的冷启动用户的未知用户-物品交互。同样，式 (15) 可通过第 2.2 节中提到的常微分方程求解器求解。

3.4 免训练流程

值得注意的是，我们的 S²CDR 是非参数的，这意味着它无需训练阶段，且具有很高的计算效率。由于我们的模型直接处理用户-物品/物品-物品交互矩阵 $\boldsymbol{R}^{st}$/ $\tilde{\boldsymbol{P}}$，因此无需使用神经网络来学习用户/项目嵌入。此外，我们引入常微分方程求解器，以连续时间方式推断式 (12) 和式 (15)，进一步缩短了整体计算时间。同时，与其他当前最优基线方法相比，我们的 S² CDR 展现出最佳性能。S²CDR 的整体流程如**附录 A.3**所示。

4 实验

本节中，我们在若干真实世界数据集上进行了大量实验，以回答以下问题：

- **研究问题1：** 我们的 S²CDR 与最先进的基线方法（包括单领域方法和跨域方法）相比，表现如何?
- **研究问题2：** 平滑与锐化函数如何提升 S²CDR 的性能?
- **研究问题3：** 平滑过程中提出的热方程是否确实捕捉到了物品间相关性?
- **RQ4：** 平滑过程中提出的理想低通滤波器是否确实滤除了噪声信息?
- **RQ5：** 我们的 S²CDR 的计算效率如何?

4.1 实验设置

4.1.1 数据集。 遵循先前的研究 [44]，，我们在两个广受欢迎的真实世界数据集上进行了大量实验，即**豆瓣**和**亚马逊**。我们从豆瓣中选取两个相关领域，包括电影和图书，构成场景 1：电影&图书。类似地，我们从亚马逊中选取三个相关领域，包括电影和电视（称为电影）、CD 与黑胶唱片（称为音乐）、图书（称为图书），构成场景 2：电影& 音乐和场景 3：图书& 音乐。两个数据集均包含 1 到 5 的评分，用于反映用户对特定项目的偏好。由于本文考虑的是隐式反馈，我们将评分二值化为 0 和 1。具体而言，评分大于或等于 4 的记为 1，其余记为 0。对于每个跨域推荐场景，我们按照先前研究 [2, 44] 的做法，过滤掉交互少于 5 次的用户。三个跨域推荐场景的详情总结见**附录 A.4**。

4.1.2 基线方法。 我们将**S²跨域推荐** 与以下当前最优基线方法进行比较：(1) **NeuMF** [9], (2)**EMCDR** [25], (3)**DCDCSR** [43],(4)**SSCDR** [14], (5)**TMCDR** [44],(6) **LACDR** [33],(7) **DOML** [16],(8)**BiTGCF** [22],(9) **PTUPCDR** [45],(10)**CDRIB** [2],(11) **UDMCF** [23], (12) **GF-CF** [29], (13) **PGSP** [21], 和 (14) **DMCDR** [19]。这些基线方法的详细信息见**附录 A.5**。

4.1.3 评估协议。 遵循先前研究 [2, 14, 23,44]，，我们采用广泛使用的留一法 评估方法来评估模型及基线方法：仅包含 1 个正样本和 999 个随机选取的负样本。我们采用两种预测性能评估指标：HR@k （命中率）和 NDCG@k （归一化折损累计增益），其中 $k = 10$。

4.1.4 实现细节。我们使用 PyTorch 1.9.0 和 Python 3.6 实现上述方法。为确保与以往方法进行公平比较，我们根据各方法原始文献中的设置调整其超参数。对于我们的 S²CDR，用于求解平滑和锐化过程积分问题的常微分方程求解器从欧拉法、RK4 和 DOPRI 中选择。α和 β的取值在{0。1，0。2，$\cdots$1。0}中搜索。对于平滑过程，终止时间 T_b 设为 1 到 3，步数 $\frac{T_b}{s}$ 取值范围为{1，2，3，4，5}。对于锐化过程，终止时间 T_h 设为 1 到 3，步数 $\frac{T_h}{s}$从{1，2，3，4，5}中选择。此外，热容 k 设为 1。各协同推荐场景下效果最佳的超参数配置汇总于**附录 A.6**。

表1：基线方法与我们的 S²CDR 在三个跨域推荐场景中的总体性能对比。加粗结果表示最佳结果，次佳结果用下划线标出。% 提升表示我们的 S²CDR 相较于最佳基线方法的相对提升。

方法	豆瓣：电影 &图书				亚马逊：电影 &音乐				亚马逊：图书 &音乐			
	图书 →电影		电影 → 图书		音乐 →电影		电影 →音乐		音乐 →图书		图书 → 音乐	
	HR	NDCG	HR	NDCG	HR	NDCG	HR	NDCG	HR	NDCG	HR	NDCG
NeuMF	0.2390	0.1441	0.2276	0.1105	0.1530	0.0929	0.1581	0.0883	0.1395	0.0707	0.1518	0.0781
EMCDR	0.2477	0.1525	0.2342	0.1193	0.1569	0.0993	0.1662	0.0978	0.1481	0.0860	0.1621	0.0898
DCDCSR	0.2519	0.1560	0.2409	0.1221	0.1613	0.1028	0.1688	0.1026	0.1513	0.0889	0.1634	0.0935
SSCDR	0.2558	0.1547	0.2462	0.1264	0.1639	0.1051	0.1726	0.1012	0.1544	0.0920	0.1673	0.0972
TMCDR	0.2602	0.1596	0.2514	0.1285	0.1672	0.1089	0.1763	0.1041	0.1576	0.0916	0.1696	0.1009
LACDR	0.2643	0.1615	0.2527	0.1298	0.1683	0.1104	0.1775	0.1060	0.1594	0.0935	0.1710	0.1022
DOML	0.2667	0.1642	0.2553	0.1320	0.1714	0.1122	0.1795	0.1087	0.1608	0.0952	0.1715	0.1036
BiTGCF	0.2703	0.1631	0.2578	0.1349	0.1693	0.1107	0.1792	0.1076	0.1637	0.0978	0.1743	0.1055
PTUPCDR	0.2736	0.1634	0.2590	0.1356	0.1709	0.1145	0.1810	0.1094	0.1622	0.0975	0.1749	0.1067
CDRIB	0.2761	0.1662	0.2628	0.1375	0.1718	0.1140	0.1832	0.1123	0.1646	0.0989	0.1758	0.1069
UDMCF	0.2914	0.1792	0.2778	0.1543	0.1887	0.1304	0.1952	0.1236	0.1756	0.1112	0.1863	0.1174
GF-CF	0.4171	0.2168	0.2580	0.1566	0.2677	0.1813	0.2097	0.1486	0.0961	0.0481	0.1700	0.0859
PGSP	0.4301	0.2470	0.2956	0.1734	0.2710	0.1851	0.2163	0.1516	0.1003	0.0500	0.1736	0.0881
DMCDR	0.4925	0.3046	0.2825	0.1624	0.3515	0.2169	0.2968	0.1920	0.1662	0.1070	0.2643	0.1510
S²CDR	**0.5430**	**0.3302**	**0.3172**	**0.1813**	**0.3703**	**0.2420**	**0.3139**	**0.2049**	**0.1905**	**0.1159**	**0.2782**	**0.1646**
% 提升	10.25%	8.40%	7.31%	4.56%	5.35%	11.57%	5.76%	6.72%	8.49%	4.23%	5.26%	9.01%

遵循以往研究 [17, 19, 45],，我们随机选取约 20% 的重叠用户作为冷启动用户（例如，其中 10% 从电影领域迁移至图书领域进行推荐，剩余 10% 从图书领域迁移至电影领域进行推荐），而其他重叠用户的样本则用于连接源域和目标域。

4.2 总体性能（RQ1）

我们将 S²CDR 与三个跨域推荐场景中的其他最先进的基线方法进行了比较。根据表1所示结果，我们可以总结出以下观察结果。

与单域方法（例如，NeuMF）相比，跨域方法表现出更优的性能，凸显了在领域之间迁移有价值的用户偏好的重要性。此外，我们还观察到，我们的 S²CDR 始终优于基于协同过滤的方法（例如，PGSP）。这一观察结果表明，S²CDR 能够通过采用锐化过程来细化和锐化平滑后的偏好信号，从而描述用户的个性化偏好，因为这些基于协同过滤的方法可以被认为仅基于平滑过程。除此之外，尽管基于映射的方法（例如，EMCDR）和基于元学习的方法（例如，PTUPCDR）利用映射函数在领域之间迁移用户偏好，但我们提出了一种新颖的平滑-锐化范式，直接处理用户-物品/物品-物品交互矩阵，其性能大幅优于这些方法，表明了我们的方法在解决冷启动问题方面的优越性。此外，我们发现，与基于扩散模型的方法（例如，DMCDR）相比，S²CDR 能够有效提升推荐性能。这些改进归因于我们在平滑过程中设计的图滤波器，使模型能够捕捉物品间相关性并滤除高频噪声信息。总体而言，S²CDR 在所有跨域推荐场景中始终优于所有基线方法，这可归因于以下原因：（1）以无噪声的方式平滑偏好信号的平滑过程；（2）用于细化和锐化偏好的锐化过程

表2：三个跨域推荐场景中的消融实验。

场景	指标	w/o b_{heat}	w/o b_{ideal}	w/o b_{smooth}	w/o $h_{sharpen}$	S²CDR
图书 →电影	HR	0.3387	0.4995	0.1935	0.4892	**0.5430**
	NDCG	0.1959	0.2979	0.0920	0.2741	**0.3302**
电影 →图书	HR	0.2043	0.3010	0.0645	0.3010	**0.3172**
	NDCG	0.1446	0.1759	0.0205	0.1755	**0.1813**
音乐 →电影	HR	0.3424	0.2983	0.1444	0.3441	**0.3703**
	NDCG	0.2069	0.1953	0.0767	0.2245	**0.2420**
电影 →音乐	HR	0.2855	0.2230	0.1115	0.2973	**0.3139**
	NDCG	0.1748	0.1568	0.0583	0.1913	**0.2049**
音乐 →图书	HR	0.1668	0.1099	0.0823	0.1729	**0.1905**
	NDCG	0.0943	0.0529	0.0412	0.1056	**0.1159**
图书 →音乐	HR	0.2370	0.1616	0.1370	0.2684	**0.2782**
	NDCG	0.1337	0.0940	0.0798	0.1591	**0.1646**

信号，以及 (3) 以连续时间方式求解平滑和锐化函数的常微分方程求解器。我们将在后续章节分析各组件的有效性。

4.3 消融研究（研究问题2）

为评估 S²CDR 的各个组件对最终性能的贡献，我们在三个跨域推荐场景中开展消融实验，将 S²CDR 与以下四种不同变体进行比较：

- *w/o* $b_{热方程}$：此变体移除了热方程 $b_{热方程}$。
- *w/o* $b_{理想}$：此变体排除了理想低通滤波器 $b_{理想}$。
- *w/o* $b_{平滑}$：我们从模型中移除了平滑函数 $b_{平滑}$，这相当于同时移除 $b_{热方程}$ 和 $b_{理想}$。
- *w/o* $b_{锐化}$：此变体表示移除了锐化函数 $b_{锐化}$。

对比结果如表2所示。我们观察到，S²CDR 的表现显著优于 *w/o* b_{heat} 变体，验证了热方程 b_{heat}的有效性，该方程旨在捕捉跨领域的物品间相关性。同时，我们还发现，移除 b_{ideal} 会导致性能下降。这一观察结果表明，使用

表3：三个跨域推荐场景中的物品间相似度分析。

场景	指标	w/ $\tilde{P}_{source}$	w/ $\tilde{P}_{target}$	S²跨域推荐
图书 →电影	HR	0.2526	0.3064	**0.5430**
	NDCG	0.1583	0.1806	**0.3302**
电影 →图书	HR	0.2580	0.2634	**0.3172**
	NDCG	0.1601	0.1595	**0.1813**
音乐 →电影	HR	0.1645	0.3535	**0.3703**
	NDCG	0.0911	0.2174	**0.2420**
电影 →音乐	HR	0.3100	0.1260	**0.3139**
	NDCG	0.1924	0.0685	**0.2049**
音乐 →图书	HR	0.0510	0.1829	**0.1905**
	NDCG	0.0330	0.1056	**0.1159**
图书 →音乐	HR	0.2648	0.1382	**0.2782**
	NDCG	0.1606	0.0763	**0.1646**

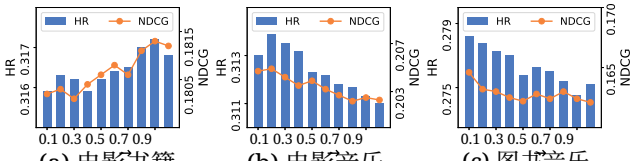

图 2：改变 b_{heat}强度（α）的效果。

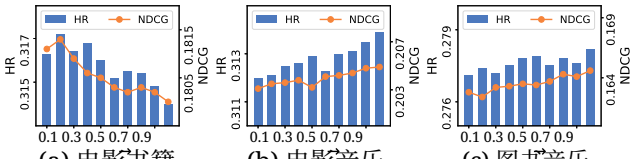

图 3：改变 b_{ideal}强度（β）的效果。

理想低通滤波器滤除高频噪声信息十分重要。另一个观察结果是，移除 b_{smooth} 时性能下降幅度最大，这表明我们在平滑过程中设计的定制图滤波器是有效的，并且应结合 b_{heat} 和 b_{ideal} 以获得更好的推荐性能。最后，与 $b_{sharpen}$ 变体相比，S²CDR 进一步提升了性能。这一发现验证了锐化过程对于在我们的模型中描述用户的个性化偏好不可或缺。

4.4 物品-物品相似度分析（RQ3）

为更好地理解热方程 b_{heat} 捕捉跨领域物品间相关性的能力，我们在单一领域中构建物品-物品相似度图（即，$\tilde{P}_{source}$ 在源领域中，P_{target} 在目标领域中），并与表 3 中跨领域的物品-物品相似度图 $\tilde{P}$ 进行比较（参见第 2.3 节）：

• w/ $\tilde{P}_{源}$：此变体将式（9）和（14）中的 $\tilde{P}$ 替换为 $\tilde{P}_{源}$。• w/ $\tilde{P}_{目标}$：此变体将式（9）和（14）中的 $\tilde{P}$ 替换为 $\tilde{P}_{目标}$。从表 3 所示结果可以看出，与w/ P_{source} 变体和w/ P_{target} 变体相比，S²CDR 在全部三个跨域推荐场景中始终表现最佳，这表明我们设计的 P 能够有效捕捉不同领域间物品的相关性。另一个观察结果是，对于目标域中的冷启动用户，例如场景 2 中的音乐 领域，P_{source} 变体的表现远优于 P_{target} 变体，这表明跨领域迁移物品间相似度有助于冷启动用户的偏好建模。

我们进一步探究热方程 b_{heat} 的强度（即，式（11）中的 α）如何影响模型捕捉跨领域物品间相关性的能力，如图 2 所示。对于电影→ 图书，我们发现 S²跨域推荐的性能会随着 α 的增大而提升。这可能是因为在交互较少的跨域推荐场景中，物品间相关性有限，需要较大的 α来捕捉。相反，对于另外两个交互更丰富的跨域推荐场景，较小的 α 就足以捕捉跨领域物品间的相关性。

4.5 噪声过滤分析（RQ4）

为验证理想低通滤波器 b_{ideal} 过滤高频噪声信息的有效性，我们调整了图 3 中 b_{ideal} 的强度（即，式（11）中的 β）。我们发现，在电影 → 图书场景中，较小的 β 即可取得良好的性能。这一观察结果可归因于交互较少的跨域推荐场景中噪声信息较少，因此较小的 β就能将其滤除。另一个观察结果是，由于交互更丰富的跨域推荐场景（例如，电影→ 音乐和图书 → 音乐）包含更多噪声信息，因此需要较大的 β将其滤除。

我们还通过表 4 中的案例研究，对比了w/o b_{ideal} 变体与 S² CDR 的噪声过滤能力。具体而言，我们从豆瓣中图书 领域到电影 领域的数据中随机选择了一位用户。数据集中提供了该用户的交互历史。值得庆幸的是，豆瓣数据集的图书 领域提供了图书标签，因此我们可以轻松获取用户在图书 领域的偏好。由此我们发现，该用户在图书 领域的偏好大致可分为三类：冒险（五本书）、奇幻（一本书）和浪漫（一本书），分别以红色、橙色和蓝色表示。我们还发现，该用户在电影 领域只观看冒险电影，这意味着该用户在图书 领域的奇幻和浪漫偏好属于噪声信息。我们将该用户视为冷启动用户，以预测其在电影 领域中的潜在交互，其中真实标签以红框标出。从表 4 所示的结果可以看出，w/o b_{ideal} 变体无法区分噪声偏好（即橙框中的奇幻偏好和蓝框中的浪漫偏好）。相比之下，我们的 S²CDR 成功过滤掉了噪声信息，进一步证明了 b_{ideal}的有效性。

4.6 计算效率分析（RQ5）

我们在表 5 中全面评估了 S²CDR 和基于扩散模型的方法 DMCDR 的计算效率，包括可训练参数、训练时间和推理时间。作为一种非参数方法，我们的 S²CDR 无需训练。相比之下，如表 5 所示，DMCDR 需要大量可训练参数。在我们的方法中，需要通过预处理步骤计算 R^{st}、$\tilde{P}$ 等，因此我们用预处理时间与 DMCDR 的训练时间进行比较。从表 5 的结果还可以看出，我们的方法在训练和推理上的时间开销均低于 DMCDR，这表明 S²CDR 具有较高的计算效率。

表4：豆瓣中从图书 领域到 电影 领域的冷启动用户案例研究。

预测（@10）	1st	2nd	3rd	4th	5th	6th	7th	8th	9th	10th
w/o b_{ideal}										
S²CDR										

表 5：DMCDR 与我们的 S²CDR 在参数量和训练/推理时间方面的分析。由于我们的方法没有训练阶段，因此将 S²CDR 的预处理时间与 DMCDR 的训练时间进行比较。

DMCDR/S²跨域推荐	电影与书籍		电影与音乐		书籍与音乐	
	图书 →电影	电影 → 图书	音乐 →电影	电影 → 音乐	音乐 →图书	图书 → 音乐
#参数	71.52M/0		21.17M/0		72.30M/0	
#训练时间	8.2秒/4.3秒	12.0秒/4.8秒	55.9秒/32.2秒	58.7s/27.0s	55.3秒/51.5秒	49.6秒/36.9秒
#推理时间	13.1秒/11.4秒	11.3秒/6.7秒	126.4秒/109.3秒	115.2秒/92.6秒	174.8秒/150.6秒	168.5秒/135.2秒

5 相关工作

传统的**跨域推荐**（CDR）旨在解决目标领域中重叠用户的数据稀疏问题 [1, 12, 42]。这些 CDR 方法利用源域中的辅助信息，提升稀疏目标领域中的推荐性能。然而，对于在目标领域中没有交互的冷启动用户，这些方法无法进行推荐。

作为一个更具挑战性的问题，利用跨域推荐来解决冷启动问题 [14, 17–19, 23, 25, 45] 已吸引了许多研究者的关注。关于这一问题的经典跨域推荐工作大致可分为两类，即基于映射的方法和基于元学习的方法。基于映射的方法 [14, 23, 25]旨在对齐并转换跨领域的用户/物品表示。具体而言，EMCDR [25] 是最流行的基于映射的方法，它首先在两个域中预训练用户/物品表示，然后学习一个映射函数，以跨领域迁移用户偏好。SSCDR [14] 通过在半监督学习中利用深度度量学习映射用户/物品表示，进一步扩展了EMCDR。UDMCF [23] 提出了结合典型子群发现算法的不平衡分布最优传输，用于用户分布映射。基于元学习的方法 [17, 31, 44, 45] 采用元学习范式来跨领域映射特征。TMCDR [44] 和PTUPCDR [45] 为每个用户提出映射函数，以借助元网络迁移其个性化偏好。CDRNP [17] 引入神经过程来捕捉重叠用户与冷启动用户之间的偏好相关性。除上述两种范式外，DMCDR [19] 采用扩散模型，在源域用户偏好的引导下生成目标域中的个性化用户表示。

基于GSP的协同过滤凭借出色的性能和较高的计算效率，在推荐系统中受到了广泛关注 [4, 15, 21, 29, 36–38, 46]。具体而言，GF-CF [29] 提出了一种统一的、基于图卷积的框架，并结合线性滤波器和理想低通滤波器进行推荐。PGSP [21] 采用混合频率图滤波器，在全局和局部层面平滑信号，以进行用户偏好建模。FIRE [36] 通过设计时间信息滤波器和侧信息滤波器，提高了计算效率，并捕捉用户/物品的时间动态。BSPM [4] 引入模糊-锐化过程，以提升推荐性能。CGSP [15] 采用跨域相似图，缓解源域和目标域之间的内在差异。FaGSP [37] 设计了两个滤波模块，用于捕捉独特和共有的用户/物品特征以及高阶邻域信息。HiGSP [38] 通过线性组合簇级滤波器和全局感知滤波器，识别用户匹配交互模式。

不同于以往的方法，我们提出了平滑-锐化过程模型，这是一种新颖的免训练框架，创新性地将图信号处理（GSP）理论应用于跨域推荐，以捕捉可迁移的物品相关性和内在用户偏好。尽管无需训练，S²CDR 仍达到了当前最优水平，证实了 GSP 所支持的损坏-恢复范式高效且有效，并启发了新的研究视角。

6 结论与未来工作

本文提出了一种面向冷启动用户跨域推荐的新型平滑-锐化过程模型（S²CDR），该模型采用损坏-恢复架构，并可通过常微分方程以连续方式求解。平滑过程通过专门设计的图滤波器，以无噪声的方式逐步将从两个领域中得到的用户-物品/物品-物品交互矩阵损坏为平滑后的偏好信号；锐化过程则迭代地锐化偏好信号，以恢复冷启动用户的潜在交互。作为一种非参数方法，我们的 S²CDR 在效果和效率方面均具有显著优势。未来，我们将探索在更具挑战性的任务中应用平滑和锐化过程，例如多域推荐。

致谢

本工作得到中国国家自然科学基金（No.62406319）的资助。

参考文献

[1] Jiangxia Cao、Xixun Lin、Xin Cong、Jing Ya、Tingwen Liu和Bin Wang。2022。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。267–277。[2] Jiangxia Cao、Jiawei Sheng、Xin Cong、Tingwen Liu和Bin Wang。2022。通过变分信息瓶颈向冷启动用户进行跨域推荐。载于2022年IEEE第38届国际数据工程会议（ICDE）。IEEE，2209–2223。[3] Ricky TQ Chen、Yulia Rubanova、Jesse Bettencourt和David K Duvenaud。2018。神经常微分方程。《神经信息处理系统进展》31（2018）。[4] Jeongwhan Choi、Seoyoung Hong、Noseong Park和Sung-Bae Cho。2023。用于协同过滤的模糊-锐化过程模型。载于第46届国际ACM SIGIR信息检索研究与发展会议论文集。1096–1106。[5] Jeongwhan Choi、Jinsung Jeon和Noseong Park。2021。LT-OCF：基于可学习时间常微分方程的协同过滤。载于第30届ACM国际信息与知识管理会议论文集。251–260。[6] Xiaowen Dong、Dorina Thanou、Laura Toni、Michael Bronstein和Pascal Frossard。2020。面向机器学习的图信号处理：综述与新视角。《IEEE信号处理杂志》37，6（2020），117–127。[7] John R Dormand和Peter J Prince。1980。一类嵌入式龙格-库塔公式。《计算与应用数学杂志》6，1（1980），19–26。[8] Xiangnan He、Kuan Deng、Xiang Wang、Yan Li、Yongdong Zhang和Meng Wang。2020。Lightgcn：简化并增强用于推荐的图卷积网络。载于第43届国际ACM SIGIR信息检索研究与发展会议论文集。639–648。[9] Xiangnan He、Lizi Liao、Hanwang Zhang、Liqiang Nie、Xia Hu和Tat-Seng Chua。2017。神经协同过滤。载于第26届万维网国际会议论文集。173–182。[10] Jonathan Ho、Ajay Jain和Pieter Abbeel。2020。去噪扩散概率模型。《神经信息处理系统进展》33（2020），6840–6851。[11] Emiel Hoogeboom和Tim Salimans。2022。模糊扩散模型。arXiv预印本arXiv:2209.05557（2022）。[12] Guangneng Hu、Yu Zhang和Qiang Yang。2018。Conet：用于跨域推荐的协同交叉网络。载于第27届ACM国际信息与知识管理会议论文集。667–676。[13] Yangqin Jiang、Yuhao Yang、Lianghao Xia和Chao Huang。2024。Diffkg：用于推荐的知识图谱扩散模型。载于第17届ACM国际网络搜索与数据挖掘会议论文集。313–321。[14] SeongKu Kang、Junyoung Hwang、Dongha Lee和Hwanjo Yu。2019。面向冷启动用户跨域推荐的半监督学习。载于第28届ACM国际信息与知识管理会议论文集。1563–1572。[15] Jeongeun Lee、Seongku Kang、Won-Yong Shin、Jeongwhan Choi、Noseong Park和Dongha Lee。2024。面向跨域推荐的图信号处理。arXiv预印本arXiv:2407.12374（2024）。[16] Pan Li和Alexander Tuzhilin。2021。用于有效且高效跨域推荐的双度量学习。《IEEE知识与数据工程汇刊》35，1（2021），321–334。[17] 李晓东、Jiawei Sheng、Jiangxia Cao、Wenyuan Zhang、Quangang Li和Tingwen Liu。2024。CDRNP：通过神经过程向冷启动用户进行跨域推荐。载于第17届ACM国际网络搜索与数据挖掘会议论文集。378–386。[18] 李晓东、Jiawei Sheng、Jiangxia Cao、Xinghua Zhang、Wenyuan Zhang、Yong Sun、Shirui Pan、Zhihong Tian和Tingwen Liu。2025。面向冷启动用户跨域推荐的个性化多兴趣建模。载于2025年IEEE第41届国际数据工程会议（ICDE）。IEEE，4092–4105。[19] 李晓东、Hengzhu Tang、Jiawei Sheng、Xinghua Zhang、Li Gao、Suqi Cheng、Dawei Yin和Tingwen Liu。2025。探索用于跨域推荐的偏好引导扩散模型。载于第31届ACM SIGKDD知识发现与数据挖掘会议论文集。[20] 李晓东、Ruochen Yang、Shuang Wen、Shen Wang、Yueyang Liu、Guoquan Wang、Weisong Hu、Qiang Luo、Jiawei Sheng、Tingwen Liu等。2025。FARM：面向跨域直播推荐的频率感知模型。arXiv预印本arXiv:2502.09375（2025）。[21] Jiahao Liu、Dongsheng Li、Hansu Gu、Tun Lu、Peng Zhang、Li Shang和Ning Gu。2023。面向协同过滤的个性化图信号处理。载于2023年ACM万维网会议论文集。1264–1272。[22] Meng Liu、Jianjun Li、Guohui Li和Peng Pan。2020。通过双向迁移图协同过滤网络进行跨域推荐。载于第29届ACM国际信息与知识管理会议论文集。885–894。[23] Weiming Liu、Chaochao Chen、Xinting Liao、Mengling Hu、Jiajie Su、Yanchao Tan和Fan Wang。2024。结合协同的用户分布映射建模用于跨域推荐的滤波器。发表于《ACM Web Conference 2024论文集》。334–343. [24] Haokai Ma、Yimeng Yang、Lei Meng、Ruobing Xie 和 Xiangxu Meng。2024。多模态条件扩散推荐模型。发表于《ACM Web Conference 2024伴随论文集》。1733–1740. [25] Tong Man、Huawei Shen、Xiaolong Jin 和 Xueqi Cheng。2017。跨域推荐：一种嵌入与映射方法。发表于 IJCAI。[26] Andriy Mnih 和 Russ R Salakhutdinov。2007。概率矩阵分解。《神经信息处理系统进展》20（2007）。[27] Antonio Ortega、Pascal Frossard、Jelena Kovačević、José MF Moura 和 Pierre Vandergheynst。2018。图信号处理：概述、挑战与应用。《IEEE学报》106卷第5期（2018），808–828. [28] Severi Rissanen、Markus Heinonen 和 Arno Solin。2022。利用逆热耗散进行生成建模。arXiv预印本arXiv:2206.13397（2022）。[29] Yifei Shen、Yongji Wu、Yao Zhang、Caihua Shan、Jun Zhang、B Khaled Letaief 和 Dongsheng Li。2021。图卷积在推荐中的能力有多强？发表于第30届 ACM国际信息与知识管理会议论文集。1619–1629. [30] Daniel A Spielman。2007。谱图论及其应用。发表于第48届 IEEE计算机科学基础研讨会（FOCS'07）。[31] Caiqi Sun、Jiewei Gu、BinBin Hu、Xin Dong、Hai Li、Lei Cheng 和 Linjian Mo。2023。RE MIT：面向跨域推荐的强化多兴趣迁移。发表于 AAAI人工智能会议论文集。[32] Chunyang Wang、Yanmin Zhu、Aixin Sun、Zhaobo Wang 和 Ke Wang。2023。面向用户冷启动推荐的偏好学习解耦框架。发表于第46届ACM SIGIR信息检索研究与发展会议论文集。1168–1177.[33] Tianxin Wang、Fuzhen Zhuang、Zhiqiang Zhang、Daixin Wang、Jun Zhou 和 Qing He。2021。面向跨域推荐的低维对齐。发表于第30届 ACM国际信息与知识管理会议论文集。3508–3512. [34] Wenjie Wang、Yiyan Xu、Fuli Feng、Xinyu Lin、Xiangnan He 和 Tat-Seng Chua。2023。扩散推荐模型。发表于第46届 ACM SIGIR信息检索研究与发展会议论文集。[35] Xiang Wang、Xiangnan He、Meng Wang、Fuli Feng 和 Tat-Seng Chua。2019。神经图协同过滤。发表于第42届 ACM SIGIR信息检索研究与发展会议论文集。165–174. [36] Jiafeng Xia、Dongsheng Li、Hansu Gu、Jiahao Liu、Tun Lu 和 Ning Gu。2022。FIRE：结合图信号处理的快速增量推荐。发表于 ACM Web Conference 2022论文集。2360–2369.[37] Jiafeng Xia、Dongsheng Li、Hansu Gu、Tun Lu、Peng Zhang、Li Shang 和 Ning Gu。2024。面向协同过滤的频率感知图信号处理。arXiv预印本 arXiv:2402.08426（2024）。[38] Jiafeng Xia、Dongsheng Li、Hansu Gu、Tun Lu、Peng Zhang、Li Shang 和 Ning Gu。2024。面向协同过滤的层次化图信号处理。发表于《ACM Web Conference 2024论文集》。3229–3240.[39] Xiaolong Xu、Hongsheng Dong、Lianyong Qi、Xuyun Zhang、Haolong Xiang、Xiaoyu Xia、Yanwei Xu 和 Wanchun Dou。2024。Cmclrec：面向用户冷启动序列推荐的跨模态对比学习。发表于第47届 ACM SIGIR信息检索研究与发展会议论文集。1589–1598. [40] Yiyan Xu、Wenjie Wang、Fuli Feng、Yunshan Ma、Jizhi Zhang 和 Xiangnan He。2024。用于生成式穿搭推荐的扩散模型。发表于第47届 ACM SIGIR信息检索研究与发展会议论文集。1350–1359.[41] Zhengyi Yang、Jiancan Wu、Zhicai Wang、Xiang Wang、Yancheng Yuan 和 Xiangnan He。2024。生成你偏好的内容：通过引导扩散重塑序列推荐。《神经信息处理系统进展》36（2024）。[42] Wenhui Yu、Xiao Lin、Junfeng Ge、Wenwu Ou 和 Zheng Qin。2020。通过文本增强域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。2136–2144. [43] Feng Zhu、Yan Wang、Chaochao Chen、Guanfeng Liu、Mehmet Orgun 和 Jia Wu。2018。面向跨域与跨系统推荐的深度框架。发表于第27届国际人工智能联合会议论文集。[44] Yongchun Zhu、Kaikai Ge、Fuzhen Zhuang、Ruobing Xie、Dongbo Xi、Xu Zhang、Leyu Lin 和 Qing He。2021。面向冷启动用户跨域推荐的迁移元框架。发表于第44届 ACM SIGIR信息检索研究与发展会议论文集。1813–1817.[45] Yongchun Zhu、Zhenwei Tang、Yudan Liu、Fuzhen Zhuang、Ruobing Xie、Xu Zhang、Leyu Lin 和 Qing He。2022。面向跨域推荐的用户偏好个性化迁移。发表于第十五届 ACM网络搜索与数据挖掘会议论文集。1507–1515. [46] Yunqin Zhu、Chao Wang、Qi Zhang 和 Hui Xiong。2024。用于协同过滤的图信号扩散模型。发表于第47届 ACM SIGIR信息检索研究与发展会议论文集。

算法 1 S²CDR 的整体流程

输入：重叠用户 $\mathcal{U}^o$；冷启动用户 $\mathcal{U}^{s\setminus o}, \mathcal{U}^{t\setminus o}$；项目集 $\mathcal{V}^s, \mathcal{V}^t$；用户-物品交互矩阵 $\boldsymbol{R}^s, \boldsymbol{R}^t$。
输出：推断交互矩阵 $\hat{}\boldsymbol{R}^{st}$。

1：构建矩阵 $\boldsymbol{R}^{st}$ 和 $\tilde{\boldsymbol{P}}$。
2：在公式 (9) 和公式 (10) 中执行 b_{heat} 和 b_{ideal}。
3：使用常微分方程求解器求解公式 (12)，进行 $\frac{T_b}{s}$ 步。
4：在公式 (14) 中执行 $b_{sharpen}$。
5：使用常微分方程求解器求解公式 (15)，进行 $\frac{T_h}{s}$ 步。
6：推导得到推断矩阵 $\hat{}\boldsymbol{R}^{st}$。

表 7：三个跨域推荐场景的统计信息（重叠表示重叠用户数）。

场景	领域	用户	重叠	项目	评分
豆瓣： 电影 &图书	电影	2,712	2,209	34,893	1,278,401
	Book	2,212		95,872	227,251
亚马逊： 电影 &音乐	电影	123,960	18,031	50,052	1,697,533
	音乐	75,258		64,443	1,097,592
亚马逊： 图书 &音乐	Book	603,668	16,738	367,982	8,898,041
	音乐	75,258		64,443	1,097,592

表6：符号说明。

符号	描述
$\mathcal{D}^s, \mathcal{D}^t$	交互数据
$\mathcal{U}^s, \mathcal{U}^t$	用户集
$\mathcal{V}^s, \mathcal{V}^t$	物品集
$\mathcal{Y}^s, \mathcal{Y}^t$	评分
$\boldsymbol{R}^s, \boldsymbol{R}^t$	用户-物品交互矩阵
$\mathcal{U}^o$	重叠用户
$\mathcal{U}^{s\setminus o}, \mathcal{U}^{t\setminus o}$	冷启动用户
$\boldsymbol{R}^{st}, \tilde{\boldsymbol{R}}^{st}$	统一用户-物品交互矩阵
$\tilde{\boldsymbol{P}}$	归一化物品-物品邻接矩阵
$\hat{\boldsymbol{R}}^{st}$	推断交互矩阵
b_{heat}	热方程
b_{ideal}	理想低通滤波器
$b_{smooth}, b_{sharpen}$	平滑与锐化函数
α, β	b_{heat} 与 b_{ideal}的比率
T_b, T_h	终止时间
$T_b/s, T_h/s$	步数

A 附录

A.1 扩散模型

作为一类强大的生成模型，扩散模型（DMs）在推荐系统领域展现出优异的性能 [19, 24, 34, 41], ，其包含正向过程和反向过程。

A.1.1 前向过程. 给定输入样本 $\boldsymbol{x}_0 \sim q(\boldsymbol{x}_0)$，前向过程通过添加高斯噪声对其进行扰动：

$$q(\boldsymbol{x}_t|\boldsymbol{x}_{t-1}) = \mathcal{N}(\boldsymbol{x}_t; \sqrt{1-\beta_t}\boldsymbol{x}_{t-1}, \beta_t\mathbf{I}), \tag{16}$$

其中，$t \in \{1, \ldots, T\}$ 表示扩散步数，$\beta_t \in (0, 1)$ 表示步骤 t 中的噪声尺度，$\mathcal{N}$是高斯分布。

A.1.2 反向过程. 从噪声数据 $\boldsymbol{x}_T$ 开始，反向过程通过迭代消除噪声来重建 $\boldsymbol{x}_0$：

$$p_\theta(\boldsymbol{x}_{t-1}|\boldsymbol{x}_t) = \mathcal{N}(\boldsymbol{x}_{t-1}; \boldsymbol{\mu}_\theta(\boldsymbol{x}_t, t), \sum_\theta(\boldsymbol{x}_t, t)), \tag{17}$$

其中，$\boldsymbol{\mu}_\theta(\boldsymbol{x}_t, t)$ 和 $\sum_\theta(\boldsymbol{x}_t, t)$ 分别是由神经网络参数化的高斯分布的均值和方差。

DMCDR [19] 是将扩散模型应用于解决跨域推荐冷启动问题的代表性工作。在推理阶段，DMCDR 仅通过反向过程，即可从噪声数据生成个性化用户表示。由于 DMCDR 与我们的 S²CDR 具有相似的处理机制，因此我们正式对二者进行如下比较：

- 这两种模型都采用一系列破坏-恢复过程。然而，DMCDR处理的是用户/项目嵌入，因此需要耗时的训练阶段。相比之下，我们的S²CDR直接处理用户-项目/项目-项目交互矩阵，无需学习任何内容，计算效率更高。
- 这两种模型都旨在通过反向过程发现个性化用户偏好。具体而言，DMCDR的反向过程是一种生成过程，能够为冷启动用户生成个性化表示。在我们的S²CDR中，未知的用户-项目交互则在锐化过程中得到预测。

A.2 符号说明

我们在表6中总结了本文使用的符号。

A.3 训练算法

我们在算法1中给出了S²CDR的整体流程。

A.4 threeCDR 场景详情

我们在表 7 中总结了三个跨域推荐场景的详情。

A.5 基线方法详情

本文所用先进基线方法的详情总结如下：(1) **NeuMF** [9] 是一种流行的单域推荐方法，利用神经网络解决协同过滤问题。(2) **EMCDR** [25] 是首个基于映射的跨域推荐方法，利用映射函数在不同领域之间迁移特征。(3) **DCDCSR** [43] 采用深度神经网络，根据各用户和项目的稀疏度，在不同领域或系统之间映射潜在因子。(4) **SSCDR** [14]采用半监督方法，学习用户和项目之间的跨域关系。(5) **TMCDR** [44] 设计了一种迁移元学习框架，包含预训练阶段和元学习阶段，以隐式转换用户嵌入。(6)**LACDR** [33]提出低维对齐策略，在低维空间中对齐重叠用户表示。(7) **DOML** [16]采用双重学习和度量学习，以迭代方式进行知识迁移。(8)**BiTGCF** [22]利用图神经网络和特征迁移层，融合用户的共同偏好与领域特定偏好。(9) **PTUPCDR** [45] 遵循基于元学习的范式，为每位用户设计映射函数，以迁移其个性化偏好。(10) **CDRIB** [2] 利用信息瓶颈原理，推导出无偏的用户表示。(11) **UDMCF** [23] 结合协同过滤

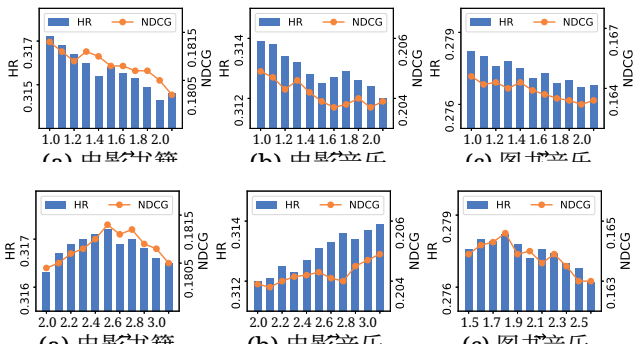

图4：改变 T_b（上）和 T_h（下）的影响。

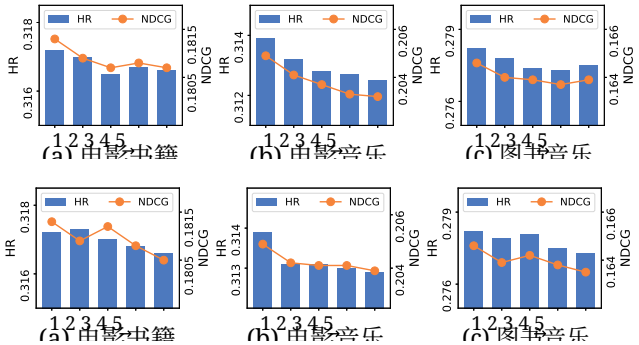

图5：改变 $\frac{T_b}{s}$（上）和 $\frac{T_h}{s}$（下）的影响。

以及分布映射过程来解决冷启动问题。(12) **GF-CF** [29] 是首个将图信号处理应用于基于图卷积网络的协同过滤的方法。(13) **PGSP** [21]引入了一种混合频率图滤波器，以捕获高频分量中的用户偏好。(14) **DMCDR** [19]是跨域推荐领域最先进的方法，它利用扩散模型，在源域用户偏好的引导下生成目标域中的用户表示。

A.6 超参数

各协同推荐场景中的最佳超参数配置如下：在电影 & 图书中，$\alpha = 0.3$, $\beta = 0.1$, $T_b = 1$, $\frac{T_b}{s} = 2$, $T_h = 2.4$，以及电影域中的 $\frac{T_h}{s} = 1$ 、 $\alpha = 0.9$、 $\beta = 0.2$、 $T_b = 1$、 $\frac{T_b}{s} = 1$、 $T_h = 2.5$ 和 $\frac{T_h}{s} = 1$ 。在 电影 & 音乐中，电影域里的 $\alpha = 0.3$、 $\beta = 1$、 $T_b = 1$、 $\frac{T_b}{s} = 1$、 $T_h = 2.8$ 和 $\frac{T_h}{s} = 1$ ，音乐域里的 $\alpha = 0.2$、 $\beta = 1$、 $T_b = 1$、 $\frac{T_b}{s} = 1$、 $T_h = 3$ 和 $\frac{T_h}{s} = 1$ 。在 图书 & 音乐中，图书域里的 $\alpha = 0.1$、 $\beta = 1$、 $T_b = 1$、 $\frac{T_b}{s} = 1$、 $T_h = 2.4$ 和 $\frac{T_h}{s} = 1$ ，音乐域里的 $\alpha = 0.1$、 $\beta = 1$、 $T_b = 1$、 $\frac{T_b}{s} = 1$、 $T_h = 1.8$ 和 $\frac{T_h}{s} = 1$ 。在所有跨域推荐场景中，平滑过程的最佳常微分方程求解器是欧拉法，锐化过程的最佳求解器是 RK4。

A.7 超参数分析

我们分析了 S²CDR 中不同超参数设置的影响，包括终止时间 T_b 和 T_h，以及步数 $\frac{T_b}{s}$ 和 $\frac{T_h}{s}$。值得注意的是，我们报告了三个跨域推荐场景中目标域冷启动用户的结果，而源域中观察结果相似的部分为节省篇幅予以省略。

A.7.1 对 T_b 和 T_h 的影响。 我们研究了 S²CDR 对平滑过程终止时间 T_b 和锐化过程 T_h 的敏感性。从图 4 所示结果可以看出，三个跨域推荐场景均在 $T_b = 1$ 时取得最佳性能，这表明平滑过程中较小的 T_b 值能够捕捉物品间相关性并滤除噪声信息。图 4 中的另一观察是，在所有三个跨域推荐场景中均可将 T_h 设为较大值，以描述用户的个性化偏好。然而，在电影 → 图书和图书 → 音乐中，S²CDR 的性能在某一点之后下降。从协同过滤的角度来看，这归因于过度应用锐化过程，因为锐化过程强调的是用户的个性化偏好而非协同信息。因此，我们应谨慎调整 T_h 的取值。

A.7.2 对 $\frac{T_b}{s}$ 和 $\frac{T_h}{s}$ 的影响。—通过改变平滑与锐化过程中常微分方程求解器的步数 $\frac{T_b}{s}$ 和 $\frac{T_h}{s}$，我们在图5中探究了S²跨域推荐的性能。我们观察到，求解平滑与锐化函数的积分问题并不需要使用很多步数，这使得我们的方法具有较高的计算效率。