DisenReason：面向共享账户序列推荐的行为解耦与潜在推理

Jiawei Cheng[a]、Min Gao[a,*]、Zongwei Wang[a]、Xiaofei Zhu[b]、ZhiyiLiu[a]、Wentao Li[c]、Wei Li[d] 和 Huan Wu [e]

[a]重庆大学大数据与软件工程学院，中国重庆，*401331*[b]重庆理工大学计算机科学与工程学院，中国重庆，*401135 c* 莱斯特大学计算与数学科学学院，英国莱斯特，*401135*[d]重庆大学附属中心医院、重庆市急救医疗中心整形外科，中国重庆，*400000*[e]同济大学环境科学与工程学院，中国上海，*200092*

arXiv:2603.03782v1 [cs.IR] 4 Mar 2026

文章信息

关键词：序列推荐 共享账户序列推荐 傅里叶变换 基于推理的推荐。

摘要

在流媒体和电子商务平台上，多位用户共用一个账户的情况十分常见。现有的共享账户序列推荐（SSR）方法通常假设每个账户对应固定数量的潜在用户，这限制了它们适应多样化共享模式的能力，并降低了推荐准确率。近期应用于序列推荐（SR）的潜在推理技术会根据用户嵌入（例如最后一个物品嵌入）生成中间嵌入，以揭示用户的潜在兴趣。这启发我们将推断潜在用户数量的问题视为生成一系列中间嵌入的过程，从推断用户背后的偏好转向推断账户背后的用户。然而，在 SSR 中，最后一个物品无法直接用于推理，因为它只能表示最近一个潜在用户的行为，而不能代表整个账户的集体行为。为此，我们提出了 DisenReason，这是一种专为 SSR 设计的两阶段推理方法。DisenReason 将从频域视角进行的行为解耦阶段与潜在用户推理阶段相结合：前者构建集体且统一的账户行为表示，作为枢纽，供后者推断账户背后的用户数量。在四个基准数据集上的实验表明，DisenReason 在所有数据集上始终优于最先进的基线方法，在 MRR@5 和 Recall@20 上分别实现最高 12.56% 和 6.06% 的相对提升。

1. 引言

在流媒体、电子商务、在线学习和智能家居平台等众多数字服务中，用户会随时间不断与系统交互，形成行为序列，这些序列揭示了他们不断演变的兴趣与需求。序列推荐（Peintner等人，2025；Liu等人，2024年；Wang等人，2024年，2025b年）已成为一种有效方案，可利用这些时间动态预测用户的下一次交互。然而，现有序列推荐系统普遍采用的一个假设是，每个账户仅由单一个人操作，而这一假设在共享账户使用十分常见的现实应用中往往并不成立。例如，家庭成员可能会联合使用同一个VIP视频账户、音乐订阅账户或网购账户。为应对这一普遍的实际场景，共享账户序列推荐（共享账户序列推荐）任务（Ma等人，2019）被提出，其目标是在多个真实用户操作同一账户时提供准确的推荐。

为解决共享账户序列推荐（SSR）任务，现有研究探索了对序列推荐模型进行扩展，例如利用循环架构编码时间依赖关系（Guo等人，2022b年，a），或利用图神经网络传播协同信号（Zhang 等，2025a）。这些方法假设每个共享账户由固定数量的潜在用户组成，并据此尝试解耦他们的序列行为。尽管这一假设简化了模型设计，却与实际使用模式不符。现实中的共享账户在底层用户数量上差异显著，从两名兄弟姐妹到数名家庭成员都有。强制采用统一且预先设定的用户数量，会限制模型适应不同共享场景的能力。因此，SSR任务中的关键挑战仍未解决：如何准确推断并表示共享账户背后潜在用户的动态数量，从而支持高质量推荐。

*通讯作者 chengjiawei@stu.cqu.edu.cn（J. Cheng）；gaomin@cqu.edu.cn（M. Gao）；zongwei@cqu.edu.cn（Z. Wang）；zxf@cqut.edu.cn（X. Zhu）；liuzhiyi@stu.cqu.edu.cn（Z. Liu）；wl226@leicester.ac.uk（W. Li）；liwei00128@cqu.edu.cn（W. Li）；wuhuan@tongji.edu.cn（H.W.）（M. Gao）

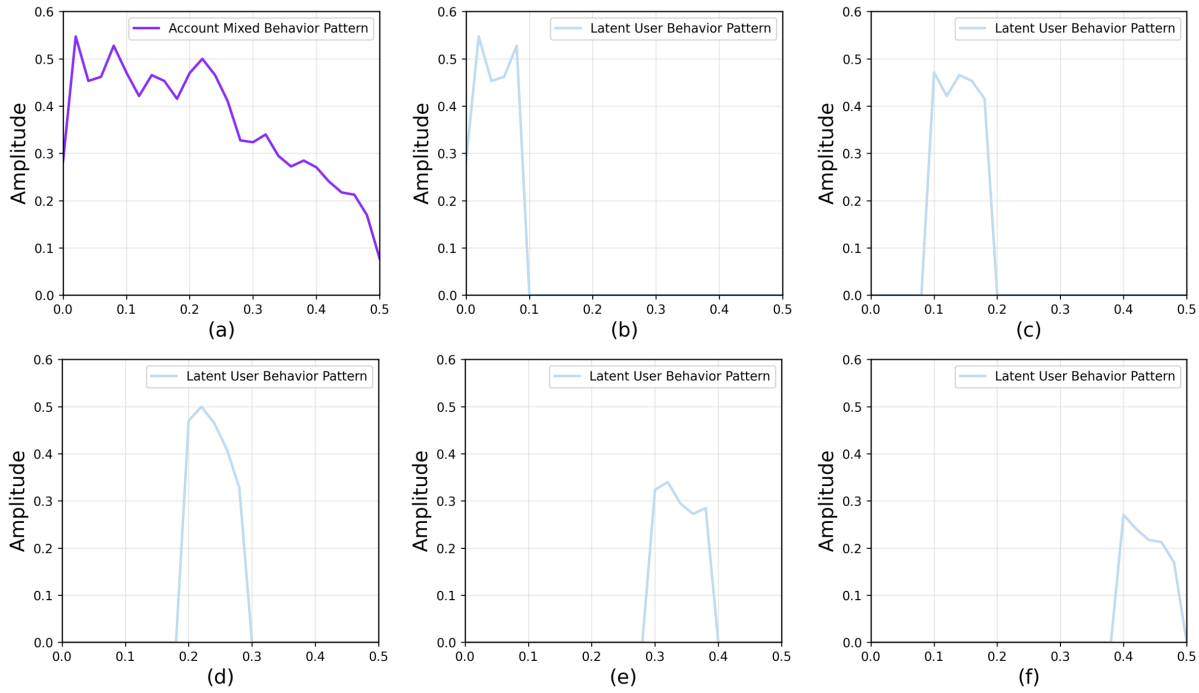

图 1. 共享账户行为序列频域解耦的可视化。

近期的潜在推理范式（Tang等人，2025）通过使模型能够基于最后一个物品的嵌入进行隐式多步推理，在序列推荐中取得了优异表现。与基于文本的推理不同，潜在推理发生在用户行为的潜在空间中，其中间结果以隐嵌入的形式呈现，代表的是多样化兴趣，而非文本。这一范式启发我们，将学习账户中潜在用户数量的问题转化为在潜在空间中生成中间结果的过程，或许是一个有前景的方向；这些中间结果表示账户的行为空间。

然而，现有的序列推荐潜在推理方法并不适用于共享账户场景。传统的序列推荐假设每个账户对应一个人。在这一前提下，自然可以将最后一个物品作为用户当前意图的表征，并将其作为推理的起始枢纽。然而，在共享账户场景中，这一假设不再成立。交互序列变成了多个潜在用户行为的混合。尽管最后一个物品可能反映了某位用户在特定时刻的行为，却无法体现共享账户的集体特性。缺少一个能够代表整个账户的统一枢纽，潜在推理方法便难以揭示账户背后的隐藏用户。因此，我们需要从这一混合交互序列中提取一个全局行为枢轴，以捕捉集体动态。

为应对这一挑战，我们采用时序信号视角，将共享账户行为视为多种时序模式的混合。信号处理理论（Pitas，2000；Acharya和Ray，2005）指出，纠缠信号可以分解为频率各异的正弦分量，其中低频代表稳定、长期的来源，高频则代表不稳定、短期的来源。类似地，我们认为共享账户中的不同潜在用户也呈现出不同的时间节律：一些用户主导稳定的长期偏好（低频），另一些用户则贡献突发性的短期交互（高频）。这一洞见促使我们考察共享账户序列中蕴含的频率结构。实证分析验证了这一观点。如图 1所示，混合交互序列呈现出宽广且连续的能量分布。随后，我们沿频率轴将这一混合分布解耦为等宽区间，得到五个不同的频率分量。这些解耦后的分量各自在相应频带内呈现能量集中，彼此之间几乎没有重叠。这一现象表明，我们可以从频域视角捕捉混合序列中的不同用户行为模式。通过组合这些分量，我们重建出账户集体行为的完整表征，从而为潜在用户推理建立一个枢纽。

基于这一洞察，我们提出了一种名为**DisenReason**的新型两阶段推理框架，旨在获取用于推理枢轴的账户级表示，并通过围绕该枢轴进行潜在推理，揭示账户背后的用户数量。在第一阶段，DisenReason 将混合的交互序列重新诠释为

频域，使用快速傅里叶变换 (FFT)(Brigham，1988) 将其解耦为不同的行为模式。由于这些模式对共享账户的贡献各不相同，我们引入混合专家 (Chen 等人，2022年) 融合方案，对它们进行自适应加权并整合，从而得到可靠的账户级表示，作为后续推理的枢轴。在第二阶段，DisenReason 通过渐进式残差推理，基于该枢轴依次揭示潜在用户。每一步都会从枢轴生成一个中间嵌入，用以表示已识别的用户，随后利用残差技术从枢轴中移除该推断用户，以避免冗余推理。当新推断出的用户与先前识别的用户之间的语义相似度超过预设阈值时，推理循环便会结束，这表明共享账户背后的所有潜在用户均已成功恢复。在四个基准数据集上的实验表明，我们提出的 DisenReason 优于以往最先进的基线方法。

本文的主要贡献总结如下：

- 据我们所知，这是首项将潜在推理引入共享账户序列推荐任务的工作。这种新颖的方法旨在应对共享账户场景中准确识别隐藏用户的挑战。

- 我们提出了 DisenReason，这是一种新颖的两阶段推理框架，它融合了行为解耦，以生成账户行为表示，随后在这些表示上执行潜在推理，旨在推断账户背后的潜在用户数量。

- 在四个基准数据集上开展的大量实验表明，在各种共享账户场景中，DisenReason 的表现始终优于最先进方法，证实了其有效性和稳健性。

2. 相关工作

2.1. 序列推荐

序列推荐（SR）旨在通过对行为序列中物品之间的转移依赖关系进行建模，预测用户的下一次交互。早期方法依赖基于马尔可夫链的模型（He and McAuley, 2016；Rendle et al.），以缓解数据稀疏性问题。然而，这些方法难以捕捉用户偏好的动态变化。随着深度学习的快速发展，各种神经序列推荐模型（Peintner et al., 2025；Liu et al., 2024；Li et al., 2026；Jiang et al., 2026；Wang et al., 2026）被引入，以学习更具表达力的序列表示。随后，自注意力机制（Vaswani et al., 2017）在对序列数据中的长程依赖关系进行建模方面展现出显著效果，促进了一系列基于 Transformer 的序列推荐模型的发展（Kang and McAuley, 2018；Sun et al., 2019；Deng et al., 2025；Pan et al., 2026；Liu et al., 2025）。尽管取得了成功，大多数此类模型都假设账户与用户之间存在一一对应关系，因此不适用于共享账户场景。

在序列推荐研究的基础上，共享账户序列推荐（SSR）将任务扩展到多个用户共用一个账户的场景（Verstrepen and Goethals，2015；Duan and Liang，2025；Wang et al.，2025a）。其核心目标是捕捉潜在用户的异质偏好，并生成个性化推荐。早期的共享账户序列推荐研究主要采用基于 RNN 的框架（Ma et al.，2019；Sun et al.，2021）来推断共享账户中的用户特定模式。然而，这些模型往往存在梯度消失问题，且难以捕捉长程依赖关系。为解决这些缺陷，后续研究（Guoetal.，2021，2022b）提出了增强注意力机制的基于图的共享账户序列推荐架构，使用户相关信号能够通过图结构传播。另有研究（Guo et al.，2022a）采用基于强化学习的方法进行共享账户序列推荐。尽管此类方法取得了显著进展，但它们通常假设所有账户的潜在用户数量固定，并直接从混合交互序列中学习，这限制了其有效解耦用户行为的能力，最终制约了推荐准确率。

相比之下，我们提出的两阶段推理方法以渐进式推理的方式，自适应地学习每个共享账户中的正确潜在用户数量，从而实现更准确、更个性化的推荐。

2.2. 基于推理的推荐

受大语言模型思维链的启发（Wei等人，2022年；Geiping等人，2025；Chen等人，2025），Tang等人（2025）将“先思考再行动”范式引入序列推荐，通过隐式推理增强序列推荐的计算能力。为此，他们提出了两种推理学习方法：集成推理学习（ERL）和渐进式推理学习（PRL）。前者借鉴集成学习的思想，构建多阶用户表示，旨在从不同视角全面捕捉潜在兴趣分布。后者的核心思想是设计一种渐进式分布锐化策略，以引导中间推理链，逐步

逼近用户的真实偏好分布。随后，PLR（Tang等人，2026）将宽度扩展计算引入序列推荐，通过同时探索多条推理轨迹，解决仅深度潜在推理的收益递减问题。该方法利用可学习触发词元在潜在空间中构建并行流，通过全局正则化保持多样性，并借助推理流混合机制自适应地聚合多流输出。

在本文中，我们将该技术应用于共享账户序列推荐。与直接将该技术应用于共享账户序列推荐不同，我们对其进行了精心设计，以更好地适配共享账户序列推荐任务。这些设计包括学习一个合适的推理枢纽作为推理起点，而不是像（Tang等人，2025）那样直接将最后一个物品作为推理起点，并在推理过程中引入残差机制，以防止冗余推理。

2.3. 推荐中的傅里叶变换

数十年来，傅里叶变换一直是数字信号处理和图信号处理中的重要工具（Pitas，2000；Acharya和Ray，2005；Peng等人，2022年；Cheung等人，2020年）。已有大量工作将傅里叶变换融入计算机视觉（Rao等人，2021；Xu等人，2020年；Suvorov等人，2022年；Zhao等人，2024年；Zhang 等，2025c年）和自然语言处理（Tamkin等人，2020年；Ai等人，2025）。近期研究尝试利用傅里叶变换增强模型进行长期序列预测（Zhou等人，2022b年；Wu等人，2025）和序列推荐。在序列推荐中，FMLP-Rec（Zhou等人，2022a年）首次引入了使用多层感知机的基于频率的滤波，以揭示用户-物品交互中的周期模式。FEARec（Du等人，2023）提出了采用频率感知注意力机制的先进架构。此外，一些研究（Qiu等人，2022年；Yang等人，2024年）将基于傅里叶的数据增强融入对比学习，进一步增强了表示鲁棒性。BSARec（Shin等人，2024年）引入了细粒度频率调整，旨在更好地捕捉细微的序列信号。MUFFIN（Baek等人，2025）采用由GFM和LFM组成的双滤波架构，以充分利用完整频谱。

尽管取得了这些进展，现有方法主要聚焦于单用户场景，假设整个交互序列都来自同一个人。相比之下，我们利用傅里叶变换对共享账户序列中的混合行为信号进行解耦，使模型能够从频域视角区分不同用户的行为模式。这种频率分析的新颖应用为在推荐系统中处理多用户账户开辟了新的可能性。

3. 研究目标

我们首先指出现有研究的局限性，随后阐述需要解决的核心问题，最后总结主要贡献，以此组织研究目标。

现有研究的局限性。 现有共享账户序列推荐方法通常假设每个账户对应固定数量的潜在用户，无法反映用户数量动态变化的真实共享场景。此外，传统的潜在推理范式依赖最后一个物品作为推理枢轴，只能捕捉最近的用户，而忽略整个账户的集体行为。

待解决的问题。 我们致力于解决两项关键挑战：（1）如何构建统一的账户级表示，以捕捉共享账户的集体行为；（2）如何在不预先设定用户数量的情况下，自适应地推断每个账户背后的潜在用户数量。

我们的研究贡献。我们提出了 DisenReason，这是一个用于共享账户序列推荐的两阶段推理框架。它包含：（1）第一阶段中的行为解耦模块，将混合序列解耦为不同的行为模式，从而构建可靠的账户枢纽；（2）第二阶段中的渐进式残差推理机制，通过迭代推断潜在用户并将其从枢纽中移除，以避免推理冗余；（3）大量实验表明，DisenReason 的表现始终优于最先进方法。

4. 预备知识

4.1. 问题定义

令 $V = \{v_1, v_2, .., v_i, .., v_n\}$ 表示物品集合，其中 v_i 表示第 i 个物品。共享账户集合记为 $\mathcal{A} = \{A_1, A_2, .., A_k, .., A_m\}$，其中 A_k 表示第 k 个共享账户。此外，序列集合记为 $S = \{S_1, S_2, .., S_k, .., S_n\}$，其中 $S_k \in \{v_1^k, v_2^k, .., v_s^k\}$ 是共享账户 A_k 的混合序列。给定 S_k 和 A_k，共享账户序列推荐的任务是基于账户的混合序列 S_k，推荐共享账户 A_k 最有可能交互的下一个物品 v_{s+1}^k。物品 v_{s+1}^k 的概率定义如下：

$$P(v_{s+1}^k \mid S_k, A_k) \sim f(S_k, A_k), \tag{1}$$

其中，$P(v_{s+1}^k \mid S_k, A_k)$ 表示给定其历史混合序列S_k时向 A_k 推荐 v_{s+1}^k 的概率，而 $f(S_k, A_k)$ 是用于估计该概率的函数。

表 1 DisenReason 中使用的符号

符号	定义
$\mathcal{A}$	共享账户集合
A_j	第 j 个共享账户
V	物品集合
v_i	第 i个物品
$\mathcal{M}$	交互矩阵，其中 $\mathcal{M}_{ij} = 1$ 表示账户 A_i 与物品 v进行过交互 $_j$
$S_k = [v_1^k, v_2^k, \dots, v_s^k]$	账户 A_k 按时间顺序排列的交互序列
m	账户数量
n	物品数量
d	嵌入维度
$\mathbf{E}_A, \mathbf{E}_V$	通过 ID 查找获取的初始账户和物品嵌入
$\mathbf{H}_A, \mathbf{H}_V$	LightGCN 传播后的最终账户和物品嵌入
$\mathbf{H}_{\text{seq}}$	账户的序列表示（从 $\mathbf{H}_V$ 查找的物品嵌入）
$\mathcal{F}, \mathcal{F}^{-1}$	快速傅里叶变换及其逆变换
$\mathbf{F}_{\text{seq}}$	序列的频域表示，$f = \lceil s/2 \rceil$
B	频率分解的带宽
$Z = \lceil f/B \rceil$	频率子带的数量
$\mathbf{F}_{\text{seq}}^{(z)}$	第 z个频率子带，$\mathbb{R}^{B\times d}$
$\tilde{\mathbf{H}}_{\text{seq}}^{(z)}$	第 z种行为模式的时域表示（经快速傅里叶逆变换和填充后）
$\mathbf{w}_f$	行为模式的自适应融合权重
$\bar{\mathbf{H}}_{\text{seq}}$	融合多行为序列表示
$\bar{\mathbf{h}}_{seq} = \bar{\mathbf{H}}_{\text{seq}}[-1]$	推理枢轴（融合序列的最后一个隐藏状态）
$\mathbf{r}_p$	可学习推理位置嵌入
$\mathbf{r}^{(t)}$	步骤 t 的推理状态（初始化为 $\mathbf{r}^{(0)} = \bar{\mathbf{h}}_{seq} + \mathbf{r}_p$）
$\phi(\cdot)$	推理函数（与第一阶段解耦共享）
$\mathbf{u}^{(t)}$	第 t 个潜在用户的推断表示
T	该账户的推断的潜在用户总数
α	用于终止渐进式推理的相似度阈值
$\mathbf{h}_{\text{final}}$	所有推断用户的聚合账户表示
$\mathbf{W}_A, \mathbf{b}_A$	用于最终预测的变换矩阵和偏置
$\mathcal{L}_{\text{rec}}$	推荐的交叉熵损失
$\mathcal{L}_{\text{aux}}$	基于中间用户表示的辅助推荐损失
β	辅助损失的权重
L	LightGCN层数

4.2. 傅里叶变换

离散傅里叶变换（DFT）是一种常用于数据分析、信号处理和机器学习的计算方法。给定有限序列 $\{x_i\}_{i=1}^n$，DFT通过以下方式将原始序列转换为频域中的频率信号：

$$X_k = \sum_{i=1}^{n} x_i W_n^{ik}, 1 \leqslant \mathrm{k} \leqslant \mathrm{n}, \tag{2}$$

其中，n 表示序列长度，W_n^{ik}是旋转因子，X_k 是表示频率为 $\omega_k = 2\pi k/n$的信号的复数。因此，我们可以将一系列数值分解为不同的频率分量。值得注意的是，DFT是时域与频域之间的一一对应映射。频域表示 X_k 可以通过离散傅里叶逆变换（IDFT）转换回时域表示，其公式如下：

$$x_i = \frac{1}{n} \sum_{k=1}^{n} X_i W_n^{-ik}, \tag{3}$$

对于实数输入 x_i，已证明其离散傅里叶变换具有共轭对称性，即 $X_k = X_{n-k}^*$，其中 $*$ 表示共轭运算。这表明，离散傅里叶变换的一半便包含完整的频率特征。若对 $\{X_k\}_{k=1}^{\lceil n/2 \rceil + 1}$ 执行离散傅里叶逆变换（IDFT），即可恢复实信号。快速傅里叶变换（FFT）算法是一种用于计算离散傅里叶变换的快速算法，可将离散傅里叶变换的计算复杂度从 $\mathcal{O}(N^2)$ 降至 $\mathcal{O}(NlogN)$。逆快速傅里叶变换（IFFT）的形式与离散傅里叶变换相似。本文分别用 $\mathcal{F}$ 和 $\mathcal{F}^{-1}$表示快速傅里叶变换和逆快速傅里叶变换。

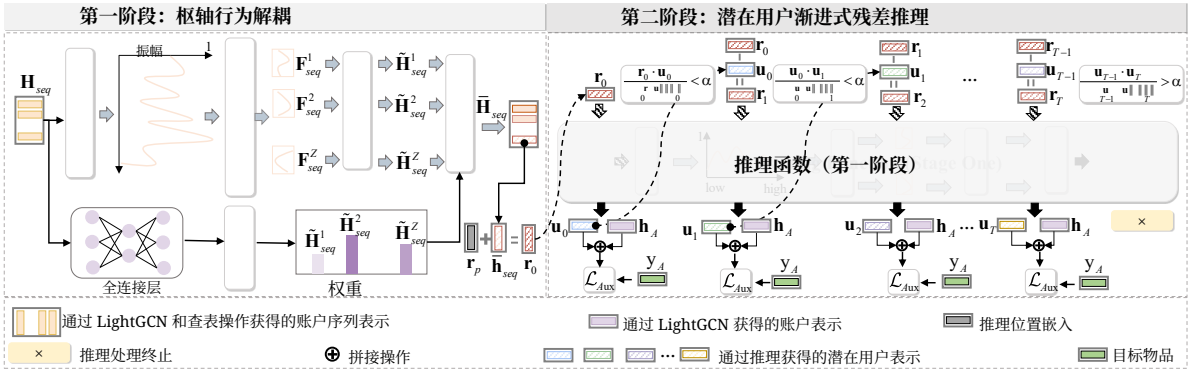

图2。 所提出的 DisenReason 框架概览。该图展示了 DisenReason 的详细内容：第一阶段侧重于对混合行为序列进行解耦，以创建统一的账户枢纽；第二阶段则基于该枢纽逐步推断潜在用户。

算法1 DisenReason 的前向传播

输入：共享账户 A_k 及其交互序列 $S_k = [v_1^k, v_2^k, \ldots, v_s^k]$；联合训练得到的 LightGCN 嵌入 $\mathbf{H}_{\mathcal{A}}$ 和 $\mathbf{H}_V$。输出：预测下一物品概率 $P(v_{s+1}^k \mid S_k, A_k)$。第一阶段：枢轴行为解耦 1：根据 S_k查找 $\mathbf{H}_V$，得到序列表示 $\mathbf{H}_{seq}$。2：计算快速傅里叶变换：$\mathbf{F}_{seq} = \mathcal{F}(\mathbf{H}_{seq})$，其中 $f = \lceil s/2 \rceil$。3：将频率轴划分为 $Z = \lceil f/B \rceil$ 个等宽子频带 B：$\mathbf{F}_{seq}^{(z)} = \mathbf{F}_{seq}[b_z : b_{z+1}]$、$b_z = z \cdot B$、$z = 1$、…、$Z$。4：对于每个子频带 z，执行以下操作：5：将 $\mathbf{F}_{seq}^{(z)}$ 补零至长度 f，并应用逆快速傅里叶变换：$\tilde{\mathbf{H}}_{seq}^{(z)} = \mathcal{F}^{-1}(ZeroPad(\mathbf{F}_{seq}^{(z)}))$。6：循环结束。7：计算自适应融合权重：$W_f = Softmax(FC(\mathbf{H}_{seq}))$。8：得到融合序列：$\tilde{\mathbf{H}}_{seq} = \sum_{z=1}^{Z} w_{f,z} \tilde{\mathbf{H}}_{seq}^{(z)}$。9：提取推理枢轴：$\mathbf{p} = \mathbf{H}_{seq}[-1]$（最后一个隐藏状态）。第二阶段：潜在用户渐进式残差推理 10：初始化推理状态：$\mathbf{r}^{(0)} = \mathbf{p} + \mathbf{r}_p$，其中 $\mathbf{r}_p$ 是可学习推理位置嵌入。11：设置 $t = 1$。12：重复执行以下操作：13：推断第 t个潜在用户：$\mathbf{u}^{(t)} = \phi(\mathbf{r}^{(t-1)})$，其中 ϕ 是推理函数（通过将同一解耦模块应用于单个向量实现）。14：残差更新：$\mathbf{r}^{(t)} = \mathbf{r}^{(t-1)} - \mathbf{u}^{(t)}$。15：如果 $t \geq 2$ 且 $cosine_similarity(\mathbf{u}^{(t)}, \mathbf{u}^{(t-1)}) > \alpha$，则：16：跳出循环 当连续推断的用户过于相似时终止。17：结束条件判断。18：$t = t + 1$。19：直至满足终止条件。20：$T = t$（推断用户数量）。21：聚合用户表示：$\mathbf{h}_{final} = \frac{1}{T} \sum_{t=1}^{T} \mathbf{u}^{(t)}$。预测 22：计算下一物品概率：$P(v_{s+1}^k \mid S_k, A_k) = \text{Softmax}\left(\mathbf{W}_A \cdot [\mathbf{h}_{final}; \mathbf{h}_A] + \mathbf{b}_A\right)$。

–

5. 提出的框架：DisenReason

本节介绍 DisenReason。该方法能够通过自我推理，自适应地学习共享账户中的潜在用户数量。如图 2所示，DisenReason 的整体框架分为两个阶段：第一阶段旨在学习推理枢轴，第二阶段则以渐进式推理的方式利用该推理枢轴推断潜在用户的数量。关键符号及其含义汇总于表 1。

DisenReason 的伪代码见算法1。下文将详细介绍 DisenReason 的公式表述与设计。

5.1. 第一阶段：行为解耦——面向枢纽的推理

下游推理的有效性本质上取决于输入表示的质量。在我们的框架中，初始账户和物品嵌入通过标准嵌入层获得，该嵌入层将每个ID映射为一个 d维向量。此类基于ID的嵌入在语义上较弱，因为它们仅编码身份信息，而不包含任何协同上下文。若将这些原始嵌入直接输入后续的两阶段推理过程，将阻碍模型准确推断潜在用户的能力。为解决这一问题，我们在进入核心推理阶段之前，通过融入全局协同信号来丰富初始嵌入。

具体而言，我们构建交互矩阵 $\mathcal{M} \in \mathbb{R}^{m\times n}$，其中 $\mathcal{M}_{ij} = 1$ 表示账户 A_i与物品v_j发生了交互。令 $\mathbf{E}_{\mathcal{A}} \in \mathbb{R}^{m\times d}$ 和 $\mathbf{E}_V \in \mathbb{R}^{n\times d}$ 分别表示账户和物品的初始嵌入矩阵。给定 $\mathbf{E}_{\mathcal{A}}$、 $\mathbf{E}_V$和 $\mathcal{M}$，我们采用 LightGCN（He等人，2020年）在全局交互图上传播协同信号。LightGCN是一种轻量级图卷积网络，它通过去除非线性变换和特征变换来简化传统图卷积网络，同时保留核心的邻域聚合操作。图卷积可表述如下：

$$\mathbf{E}_{\mathcal{A}}^{(l+1)} = \tilde{\mathcal{M}}\mathbf{E}_V^{(l)},\ \mathbf{E}_V^{(l+1)} = \mathbf{E}_{\mathcal{A}}^{(l)}\tilde{\mathcal{M}}. \tag{4}$$

$$\tilde{\mathcal{M}} = D^{-\frac{1}{2}}\mathcal{M}D^{-\frac{1}{2}}, \tag{5}$$

其中 $D \in \mathbb{R}^{m\times n}$ 是度矩阵。在应用 L 层图卷积之后，从所有层得到的每个节点嵌入通过平均池化进行聚合，从而得到账户和物品的最终表示。形式上，最终嵌入定义如下：

$$\mathbf{H}_{\mathcal{A}} = \frac{1}{L}\sum_{l=1}^{L}\mathbf{E}_{\mathcal{A}}^{(l)}, \mathbf{H}_V = \frac{1}{L}\sum_{l=1}^{L}\mathbf{E}_V^{(l)}, \tag{6}$$

其中$\mathbf{H}_{\mathcal{A}} \in \mathbb{R}^{m\times d}$ 和$\mathbf{H}_V \in \mathbb{R}^{n\times d}$。$\mathbf{E}_{\mathcal{A}}^{(l)}$ 和$\mathbf{E}_V^{(l)}$ 表示第 l层的账户表示和物品表示。基于物品表示矩阵$\mathbf{H}_V$，我们可以根据输入账户的交互序列 $S_A \in \{v_1, v_2, \cdots, v_s\}$得到账户序列表示$\mathbf{S}_{\mathcal{A}}$ ，该表示将用于后续推理过程：

$$\mathbf{H}_{seq} = Lookup(\mathbf{H}_V, S_A), \tag{7}$$

其中$\mathbf{H}_{seq} \in \mathbb{R}^{s\times d}$ 是账户序列表示， s 是序列长度。 $lookup$操作检索相应的物品嵌入，并在时间上对齐它们，以形成该账户的行为序列表示。

正如引言中所确立的，构建账户级枢轴对于推理过程至关重要，因为它直接使后续阶段能够准确推断潜在用户。为此，在第一阶段，我们旨在推导出这样一个枢轴，以捕捉整个账户的集体行为，并作为对账户进行推理以揭示其底层用户的基础。

具体而言，我们首先通过将纠缠序列表示 $\mathbf{H}_{seq}$转换到频域，从而能够从频域视角解耦混合信号，进而获得相对独立的潜在行为模式表示。该操作表示为：

$$\mathbf{F}_{seq} = \mathcal{F}(\mathbf{H}_{seq}), \tag{8}$$

其中 $\mathcal{F}$表示快速傅里叶变换（FFT）操作（第 4.2节）。由于实值输入的 FFT 具有共轭对称性，只需保留一半的频率分量。因此，变换后的表示为 $\mathbf{F}_{seq} \in \mathbb{R}^{f\times d}$，其中 $f = \lceil s/2 \rceil$ 对应于唯一频率箱的数量。

为了解耦混合行为模式，我们沿频率轴将 $\mathbf{F}_{seq}$ 划分为 Z 个等宽的子频带 B。具体而言，第 z个子频带通过切取范围$[b_z, b_{z+1}]$内的频率分量获得，其中 $b_z = z \cdot B$，子频带总数为 $Z = \lceil f/B \rceil$。每个子频带 $\mathbf{F}_{seq}^{(z)} \in \mathbb{R}^{B\times d}$捕获一个特定的频率区间，对应于不同的行为节律：

$$\mathbf{F}_{seq}^{(z)} = \mathbf{F}_{seq}[b_z : b_{z+1}],\ b_z = z \cdot B. \tag{9}$$

所得频域表示 $\mathbf{F}_{seq}^{(z)}$ 包含复数值分量，无法直接使用。为获得可用的表示，我们对每个子带应用快速傅里叶逆变换，将其转换回时域。

由此得到一组时间表示，每个表示都反映了共享账户所表现出的独特行为节律。该过程可表述如下：

$$\tilde{\mathbf{H}}_{seq}^{(z)} = \mathcal{F}^{-1}(Padding(\mathbf{F}_{seq}^{(z)})), \tag{10}$$

其中，$\tilde{\mathbf{H}}_{seq}^{(z)} \in \mathbb{R}^{s\times d}$ 表示第 z 个行为模式的表示。$Padding$ 表示零填充，即扩展 $\mathbf{F}_{seq}^{(z)}$ 的频率长度，使其与 $\mathbf{F}_{seq}$的频率长度相匹配，从而能够执行逆变换。然而，并非所有频率分量对整体账户表示的贡献都相同。其中，一些分量捕捉共享账户的主导行为模式，而另一些分量则主要反映噪声或语义意义有限的瞬时交互。为自适应地确定每种行为模式的贡献，我们学习不同行为模式的相对重要性，并采用加权求和。该操作定义如下：

$$W_f = Softmax(FC(\mathbf{H}_{seq})), \tag{11}$$

$$\bar{\mathbf{H}}_{seq} = \sum_{z=1}^{Z} w_f^z \tilde{\mathbf{H}}_{seq}^{(z)}, \tag{12}$$

其中，$FC(\cdot)$ 表示一个全连接层，它根据输入序列 $\mathbf{H}_{seq}$为每种行为模式学习权重$w_f^z \in W_f$。这种自适应融合机制会突出信息量最大的行为节律，同时抑制冗余或含噪分量，从而得到全面的多行为账户序列 $\bar{\mathbf{H}}_{seq}$。最后，我们将最后一个隐藏状态 $\mathbf{h}_{seq} = \mathbf{H}_{seq}[-1]$ 作为聚合后的账户级行为信号，作为后续渐进式推理阶段的推理枢轴。

5.2. 第二阶段：面向潜在用户的渐进式残差推理

在这一阶段，我们的目标是利用推理枢轴启动渐进式残差推理，从而隐式地还原共享账户背后的潜在用户。由于第二阶段的推理函数 $\phi(\cdot)$ 会重用第一阶段的同一解耦操作，若不加以适当区分，模型将无法区分这两个阶段，导致处理方式相同，并削弱推理过程。为了解决重用相同操作可能造成的混淆，我们引入推理位置嵌入 $\mathbf{r}_p$，以明确区分第二阶段与第一阶段。该嵌入与账户枢轴 $\mathbf{h}_{seq}$ 相结合，形成初始推理状态 $\mathbf{r}_0$，由此启动渐进式残差推理过程。这表明函数 $\phi(\cdot)$ 相应地发挥着双重作用。当它应用于第一阶段的序列表示$\mathbf{H}_{seq} \in \mathbb{R}^{s\times d}$ 时，会通过解耦跨交互的混合模式来执行行为级解耦。当它应用于第二阶段的推理状态 $\mathbf{r}_0 \in \mathbb{R}^d$ 时，则自然退化为映射函数，将账户级状态投影为潜在用户表示，从行为转向识别用户。

在每一步 t，推理函数 $\phi(\cdot)$ 获取当前状态 $\mathbf{r}_{(t)}$，并提取最显著的尚未发现的用户：

$$\mathbf{u}_{(t)} = \phi(\mathbf{r}_{(t)}), \quad \mathbf{r}_{(t+1)} = \mathbf{r}_{(t)} - \mathbf{u}_{(t)}, \tag{13}$$

其中，$\mathbf{u}_{(t)}$ 表示第 t 个潜在用户的推断表示。残差相减会从当前状态中移除已识别的用户，使后续步骤能够聚焦于剩余尚未解释的信号。

当连续推断出的用户在语义上变得相似时，推理过程会自适应地终止，因为这表明所有潜在用户均已被发现。这样，模型便能够自主确定每个账户中的用户数量，同时保持表示质量和计算效率。相似度的计算方式如下：

$$\mathrm{sim}(\mathbf{u}_{(t)}, \mathbf{u}_{(t-1)}) = \frac{\mathbf{u}_{(t)} \cdot \mathbf{u}_{(t-1)}}{\|\mathbf{u}_{(t)}\|_2 \, \|\mathbf{u}_{(t-1)}\|_2} > \alpha, \tag{14}$$

其中，α 是用于控制推理深度的超参数。最后，通过聚合所有推断用户的嵌入，得到整体账户表示：

$$\mathbf{h}_{final} = \frac{1}{T} \sum_{t=1}^{T} \mathbf{u}_{(t)}, \tag{15}$$

其中 T 表示推理步骤总数。

5.3. 训练目标

DisenReason 生成的最终预测表示为:

$$P(v_{s+1} \mid S, A) = \text{softmax}\left(\mathbf{W}_A \cdot [\mathbf{h}_{final}, \mathbf{h}_A]^\top + \mathbf{b}_A\right), \tag{16}$$

其中 $\mathbf{h}_A \in \mathbf{H}_A$ 是根据式 6 得到的账户表示。 $\mathbf{W}_A \in \mathbb{R}^{2d \times n}$ 是一个变换矩阵，用于将预测结果投影到候选物品的维度空间； $\mathbf{b}_A \in \mathbb{R}^{2d}$ 是偏置项。我们采用交叉熵损失函数对 DisenReason 进行优化:

$$\mathcal{L}_{Rec} = -\sum_{k=1}^{m} y_{A_k} \cdot \log P(v_{s+1}^k \mid S_k, A_k) + (1 - y_{A_k}) \cdot \log(1 - P(v_{s+1}^k \mid S_k, A_k)). \tag{17}$$

其中， y_{A_k} 是真实值的独热编码。 m 表示账户总数。为了进一步提供有效的优化信号，我们使用不同推理步骤对应的潜在用户表示作为多视图表示来计算辅助推荐损失。这一设计促使推理过程为每个推断用户学习有意义的表示。辅助推荐损失的计算方式如下:

$$y_u^{(t)} = \text{softmax}\left(\mathbf{W}_u \cdot [\mathbf{u}_{(t)}, \mathbf{h}_A] + \mathbf{b}_u\right), \tag{18}$$

$$\mathcal{L}_{Aux} = -\sum_{k=1}^{m} \sum_{t=1}^{T} y_{A_k} \cdot \log y_{u,k}^{(t)} + (1 - y_{A_k}) \cdot \log(1 - y_{u,k}^{(t)}), \tag{19}$$

其中， $\mathbf{W}_u$ 和 $\mathbf{b}_u$ 分别与 $\mathbf{W}_A$ 和 $\mathbf{b}_A$相同。对于所有潜在用户，我们采用共享的 $\mathbf{W}_u$ 和 $\mathbf{b}_u$ ，以减少训练参数总量。由此，整体训练目标定义如下:

$$\mathcal{L}_{all} = \mathcal{L}_{Rec} + \beta \mathcal{L}_{Aux}, \tag{20}$$

其中， β 是用于控制 $\mathcal{L}_{Aux}$大小的超参数。

6. 实验

本节首先介绍实验设置，然后通过回答以下**研究问题（RQs）**来分析我们提出的 DisenReason 的性能。

- **RQ1:** 与最先进的基线方法相比，我们提出的 DisenReason 表现如何?
- **RQ2:** DisenReason 中的各项设计分别有何贡献?
- **RQ3:** 关键超参数会如何影响 DisenReason?
- **RQ4:** 在序列长度和训练数据比例等不同条件下，DisenReason 的鲁棒性如何?
- **RQ5：** DisenReason 如何推断共享账户中潜在用户的真实数量?

6.1. 实验设置

6.1.1. 数据集。

我们在四个由（Ma 等人，2019）首次提出的数据集上开展实验，即 HvideoE（HV-E）、HvideoV（HV-V）、HamazonM（HA-M）和 HamazonB（HA-B）。前两个数据集 HV-E 和 HV-V 是智能电视数据集，记录了用户在不同电视频道上的观看历史。具体而言，HV-E 聚焦于教育与教学视频的日志，涵盖体育、健康和医疗内容等主题；而 HV-V 则包含娱乐内容的日志，包括电视剧和电影。其余数据集 HA-M 和 HA-B 分别来自不同的亚马逊领域，对应观影和阅读活动。在实验设置中，我们对每个数据集进行随机划分，将 80% 的用户序列用于训练，其余 20% 用于测试。需要特别指出的是，对于每个序列，我们将最近一次交互视为真实目标物品，以评估模型性能。HVIDEO 和 HAMAZON 数据集的详细信息见 表2。

6.1.2. 评估指标。

我们采用两个常用的评估指标来评估模型性能，即 Top-K 召回率（RC@K）和 Top-K 平均倒数排名（MRR@K），其中 $K = \{5, 20\}$。

表2HVIDEO 和 HAMAZON 数据集的统计信息。

	HVIDEO		HAMAZON	
	E域	**V域**	**M域**	**B域**
物品	8,367	11,404	67,161	126,547
交互次数	2,129,500	1,893,784	2,196,574	2,135,995
平均序列长度	15.85	14.09	15.27	14.84
账户	13,714		13,724	
序列	134,349		143,885	
训练序列	114,197		122,303	
测试序列	20,152		21,582	

6.1.3. 实现细节。

DisenReason 在配备 24 GB 显存的 NVIDIA RTX 4090 上使用 PyTorch 实现。操作系统为 Ubuntu 20.04，编码平台为 Visual Studio Code。我们使用 Adam优化器（Kingma，2014）对模型进行优化。对于所有数据集，最大序列长度均设置为 50。为训练 DisenReason，我们进行超参数调优，以确定最优的超参数配置，其中包括卷积层数量 $L \in \{1, 2, 3, 4, 5\}$（LightGCN 中）、频带宽度 $B \in \{1, 3, 5, 7, 9\}$（用于频率分解）、终止阈值 $\alpha \in \{0.3, 0.4, 0.5, 0.6, 0.7\}$（用于渐进式推理）以及损失权重$\beta \in \{0.1, 0.5, 1.0, 1.5, 2.0\}$。我们采用早停策略以防止过拟合。

6.1.4. 基线方法。

为评估 DisenReason 的有效性，我们将其与两类基线方法进行比较：传统序列推荐模型和共享账户序列推荐模型。

传统的序列推荐基线方法包括：

- SASRec（Kang 和 McAuley，2018）对整个用户序列进行建模（不采用任何循环或卷积操作），并自适应地考虑已消费的物品进行预测。
- GRURec（Hidasi 等人，2015）首次将门控循环单元引入推荐领域。该方法对基础门控循环单元进行了改进，以更好地适应任务，具体做法是引入会话并行小批次、基于小批次的输出采样和排序损失函数。
- FMLP-Rec（Zhou 等人，2022a年）提出了一种用于序列推荐任务的、带有可学习滤波器的全 MLP 模型。全 MLP 架构使我们的模型具有较低的时间复杂度，而可学习滤波器可通过随机梯度下降进行优化，从而自适应地衰减频域中的噪声信息。
- FEARec（Du 等人，2023）设计了一种新的基于频率的模型，在时域和频域中构建混合注意力机制。借助所定义的频率斜坡结构，FEARec 采用改进的时域注意力来学习低频和高频信息。
- BSARec（Shin 等，2024年）结合注意力归纳偏置与原始自注意力，并融合低频和高频信息以缓解过平滑。
- GLINT-RU（Zhang 等，2025b年）将稠密选择性门控循环单元与线性复杂度相结合，从而降低计算成本并加快推理速度。

共享账户序列推荐的基线方法包括：

- π-Net（Ma 等，2019）首次提出共享账户序列推荐。它利用共享账户滤波器和跨域迁移机制提升推荐效果。
- PSJNet（Sun 等，2021）提出了“拆分”和“联合”的概念。“拆分”用于识别不同用户角色的行为。“联合”用于区分并整合有用的用户行为。
- DA-GCN（Guo 等人，2021）通过图学习对用户与物品之间的多重关联以及迁移知识的结构信息进行建模。

表 3不同推荐方法的总体性能。表现最佳和次佳的方法分别以粗体和下划线字体标出。“改进幅度”表示所提方法相对于表现最佳的基线方法的相对改进比率。

模型	HV_E				HV_V				HA_M				HA_B			
	召回率@5	召回率@20	MRR@5	MRR@20	召回率@5	召回率@20	MRR@5	MRR@20	召回率@5	召回率@20	MRR@5	MRR@20	召回率@5	召回率@20	MRR@5	MRR@20
SASRec	46.84	64.11	33.23	35.01	69.98	79.48	56.34	57.34	41.95	43.75	39.41	39.59	41.32	43.86	36.87	37.15
GRURec	44.61	59.64	34.84	36.33	68.36	74.93	63.19	63.85	48.08	48.75	46.87	46.94	47.88	48.52	46.44	46.51
FMLP-Rec	44.27	60.77	34.43	36.09	70.23	76.45	65.01	65.64	48.02	48.35	47.51	47.53	48.62	48.97	48.01	48.04
FEARRec	50.38	64.08	40.77	42.15	70.66	77.22	64.86	65.53	40.86	43.58	37.25	37.54	39.78	42.16	36.92	37.17
BSARec	54.88	67.21	43.9	45.16	73.72	81.54	62.84	63.65	47.73	48.29	46.99	47.05	47.43	48.7	46.28	46.35
GLINT-RU	44.93	60.3	34.31	35.85	70.08	77.11	63.95	65.61	43.39	47.13	45.67	45.79	47.39	47.39	47.19	47.24
π-Net	25.13	47.08	15.36	17.52	67.00	74.17	60.37	61.74	18.54	21.87	16.24	16.56	23.75	23.75	20.38	20.58
PSJNet	24.80	46.68	15.37	17.56	66.86	74.14	61.89	62.63	16.25	18.14	11.25	13.68	19.3	19.30	15.52	17.30
DA-GCN	51.35	66.93	35.63	37.27	75.39	82.37	59.78	60.55	22.93	23.90	20.09	20.19	23.93	24.25	21.35	21.39
TiDA-GCN	54.11	68.98	38.66	40.23	76.37	83.58	63.58	65.37	23.55	24.33	20.91	21.23	24.69	24.82	21.88	22.21
LightGC^{2}N	61.35	72.73	46.24	47.35	79.29	84.70	66.27	66.87	46.02	48.46	41.30	41.64	47.36	48.55	44.40	44.52
Our	**63.43**	**75.01**	**52.05**	**53.25**	**81.89**	**89.83**	**67.89**	**68.78**	**49.13**	**50.05**	**48.81**	**48.88**	**49.56**	**49.73**	**49.42**	**49.44**
改进幅度 (%)	3.39	3.13	12.56	12.46	3.28	6.06	2.44	2.87	2.18	2.67	2.74	2.84	1.93	1.55	2.94	2.91

- TiDA-GCN（Guo 等人，2022b年）是 DA-GCN 的扩展版本。为增强物品和账户的表示学习，它引入了时间间隔感知消息传递策略和交互特征建模组件，进一步提升了其捕捉推荐过程中复杂依赖关系与动态变化的能力。

- LightGC^{2}N (Zhang 等，2025a)设计了一种便捷高效的胶囊卷积网络，以更好地区分物品与潜在用户之间的归属关系。

6.2. 整体性能（RQ1）

表 3 展示了我们提出的模型与多种最先进的序列推荐（SR）和共享账户序列推荐（SSR）基线方法在四个基准数据集上的整体性能比较。DisenReason 在所有四个数据集上均取得了最佳性能。具体而言，在 HV-E 和 HV-V 数据集上，DisenReason 的表现优于最强的 SSR 基线方法 LightGC^{2}N，相对提升幅度为 2.06% 至 12.47%。值得注意的是，LightGC^{2}N 的表现优于 FEARec、BSARec 和 GLINT-RU 等 SR 基线方法。这一优势凸显了在共享账户场景下显式建模潜在用户交互的益处。SR 模型假设序列中的所有行为均来自同一用户，因此无法捕捉账户内的异质偏好；而 LightGC^{2}N 利用基于图的消息传递和注意力机制传播特定用户的信息，从而实现更准确的表征学习。DisenReason 的表现优于 LightGC^{2}N，这表明，与依赖预定义数量相比，学习每个账户中实际真实用户的数量能够带来有益的性能提升。

在 HA-M 和 HA-B 数据集上，DisenReason 也取得了 1.93% 至 2.94% 的相对提升。有趣的是，作为表现最佳的共享账户序列推荐方法，LightGC^{2}N 在 HA-M 和 HA-B 数据集上的表现并未超过传统序列推荐模型。相比之下，GRURec 和 FEARec 等序列推荐方法甚至在一定程度上优于 LightGC^{2}N。进一步分析后，我们发现 HV-V 和 HV-E 是真实共享账户数据集，而 HA-M 和 HA-B 是合成数据集。因此，我们推测，这种性能差异可能源于真实与合成共享账户行为之间的根本差异。

总而言之，整体结果证实，DisenReason 能够在真实和合成共享账户场景中，更忠实且更具可解释性地表征共享账户行为，从而显著提升推荐性能。

6.3. 消融研究（RQ2）

本节开展消融研究，以考察 DisenReason 中各项关键设计的作用，包括表征构建（w/oLightGCN）、频率解耦操作（w/o Behavior Disentan- glement）、针对不同行为模式的自适应融合操作（w/o Adaptive Fusion），以及用于推理的残差操作（w/o Residual Operation）。表 4 报告了四个数据集上不同变体的性能。实验结果分析如下：

- **LightGCN 的作用**。移除 LightGCN 后，整体性能明显下降，尤其是在 HV-E 和 HV-V 上。这种性能下降表明，LightGCN 在捕捉全局账户—物品协同信号方面发挥着关键作用，而这些信号为后续模块提供了稳定的语义基础。

表 4 DisenReason 在四个数据集上的消融研究。“w/o”表示移除了相应设计的模型变体。

模型	HV-E		HV-V		HA-M		HA-B	
	RC@5	MRR@5	RC@5	MRR@5	RC@5	MRR@5	RC@5	MRR@5
去除 LightGCN	61.96	51.32	79.84	67.68	48.61	48.52	49.44	49.35
去除行为解耦	55.09	33.35	77.81	53.17	35.89	22.62	36.21	22.67
去除自适应融合	62.51	50.88	81.59	67.64	49.05	48.76	49.54	49.39
去除残差操作	63.32	51.37	81.34	67.69	49.08	**48.84**	49.50	49.32
Our	**63.43**	**52.05**	**81.89**	**67.89**	**49.13**	48.81	**49.56**	**49.39**

• **行为解耦的作用**。 在第一阶段，我们不进行行为解耦，而是直接将账户序列中的最后一个物品作为推理枢轴。移除行为解耦后，性能下降幅度在所有变体中最大。例如，在 HV-E 上，MRR@5 从 52.05 降至 33.35；在 HV-V 上，则从 67.89 降至 53.17。这种显著下降表明，获取一个能够代表整个账户的枢轴是有效的，而不是直接将账户中的最后一个物品用作枢轴。直接将账户中的最后一个物品用作用户推理的枢轴，会导致后续推理过程中对账户内潜在行为的理解不完整。在这种情况下，渐进式推理无法有效推断账户背后的隐藏用户，进而降低推荐性能。

• **自适应融合的作用**。自适应融合能够识别每种潜在行为的重要性，从而将它们组合成更贴近实际的账户级表示。移除这一操作后，所有指标均有所下降，这表明考虑账户内不同行为的重要性有助于学习更好的账户行为表示。

• **残差操作的影响**。 残差操作可防止冗余的语义解释，并使后续步骤在推理过程中聚焦于尚未解释的用户。将其移除仅会导致轻微的性能下降。这是因为残差操作起到语义精炼作用，用以打磨潜在用户语义边界。因此，移除该操作只会造成中等程度的性能下降。

6.4. 超参数敏感性（RQ3）

为了评估 DisenReason 对不同超参数设置的敏感性，我们进行敏感性实验，在 HV-V 和 HV-E 上进行，如图 3所示。分析如下：

• **超参数** B。 B 用于调节频率解耦的强度。如图 3(a) 所示，当 $B = 5$ 时， B 达到最佳性能。若其过小，可能无法充分解耦完整的行为模式，导致这些模式碎片化。相反，过大的B 可能导致行为模式仍然纠缠。因此，适中的 B 能够在解耦粒度与表征稳定性之间实现最佳平衡。

• **超参数** L。 L 控制 LightGCN 的卷积深度。从 图 3(b) 可见，随着传播层数加深，模型性能不断提升，直至 $L = 3$，随后略有下降。这表明，更深的层能够增强捕捉协同关系的能力，但也可能引入高阶噪声，从而导致过平滑。因此， $L = 3$ 在信息聚合与模型泛化之间实现了良好的权衡。

• **超参数** α。 α 在用户推理过程中充当终止信号。如 图 3(c) 所示，所提出的模型在 HV-V 和 HV-E 上分别于 $\alpha = 0.5$ 和 $\alpha = 0.4$ 时达到最佳性能。阈值 α 根据连续推断用户之间的相似度，决定何时停止推理过程。适当的 α 阈值可避免生成冗余用户。

• **超参数** β。 β 用于控制监督信号的强度。如图 3(d) 所示，当 β 分别设置为 1.0 和 0.5 时，DisenReason 在 HV-V 和 HV-E 数据集上取得了最佳性能。这表明，在渐进式推理过程（第二阶段）中提供额外的监督信号，有助于提高推理过程的多样性，进而改善推荐性能。

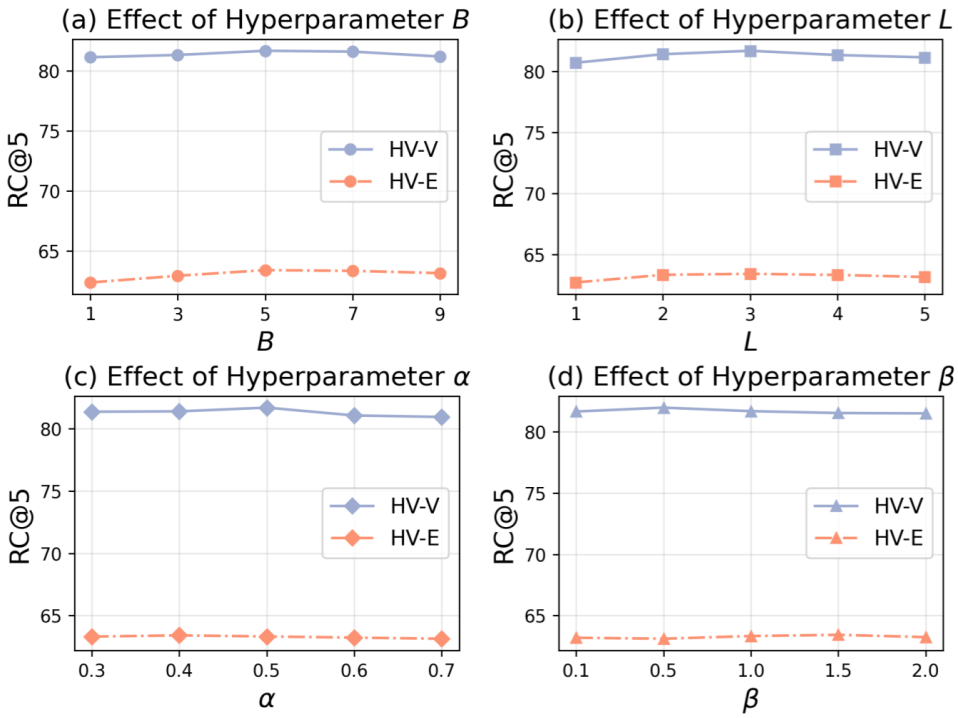

图 3. DisenReason 在 HV-V 和 HV-E 数据集上的超参数分析。

6.5. 鲁棒性分析（RQ4）

为评估 DisenReason 的鲁棒性，我们围绕序列长度和训练数据进行了两组实验。第一组实验改变最大序列长度，第二组实验控制可用训练数据的比例。如图 4所示，结果始终表明 DisenReason 具有出色的稳定性和鲁棒性。

当最大序列长度从 25 变化到 100 时，DisenReason 在 HV-V 和 HV-E 两个数据集上始终优于所有基线方法，包括 LightGC^{2}N、FMLP-Rec 和 GLINT-RU。不同于基线方法，随着序列变长，它们的性能会因噪声或冗余交互的累积而波动甚至下降；DisenReason 则能保持稳定的性能。在低资源条件下，当训练数据量从 20% 增至 100% 时，DisenReason 同样展现出显著的鲁棒性和数据效率。即使仅使用 20% 的数据进行训练，我们的模型也优于最强的基线方法。更重要的是，与基线方法相比，随着数据规模的增加，DisenReason 的性能平稳且近乎线性地提升。

6.6. 深入分析（RQ5）

本节对从 HV-E 和 HV-V 数据集中选取的 10 个账户进行了详细分析，并将其推断出的潜在用户数量可视化，如图 5所示。实验凸显了推理机制在不同账户中自适应推断潜在用户数量的有效性。结果表明，DisenReason 能够动态适应共享账户场景中不同的复杂程度。具体而言，在 HV-E 数据集中，一些账户（如 ID 为 10293 和 5673 的账户）的潜在用户数量较多，而另一些账户（如 ID 为 6304 和 2643 的账户）的潜在用户数量较少。推断出的用户数量存在这种差异，反映了模型区分具有不同交互模式和复杂程度的账户的能力。HV-V 数据集中也出现了这一现象。

本实验的关键见解是，DisenReason 中的两阶段推理过程能够有效推断潜在用户的数量，使其能够适应广泛的现实场景。在许多共享账户情境中，每个账户的用户数量并未预先设定，且可能存在显著差异。这种适应能力对于在共享账户结构不固定的情况下准确建模和预测用户行为至关重要。通过本实验，我们验证了 DisenReason 处理用户数量和交互次数固有变化的能力，展现了其在现实共享账户环境中的鲁棒性。

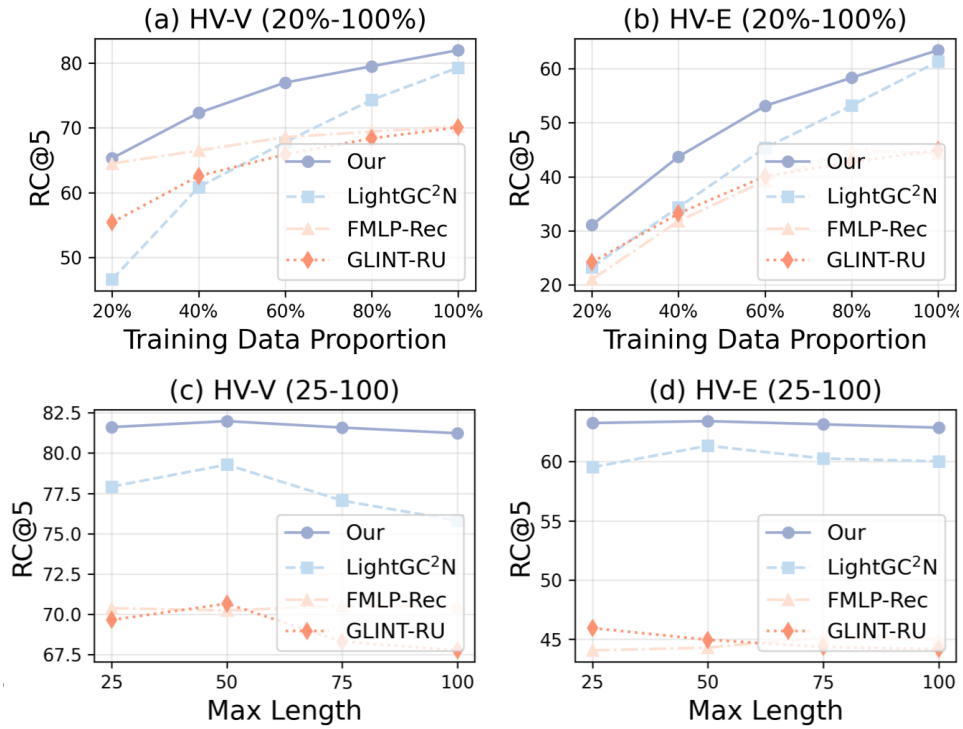

图 4. DisenReason 与基线方法在 HV-V 和 HV-E 数据集上、不同序列长度和训练数据规模下的性能比较。

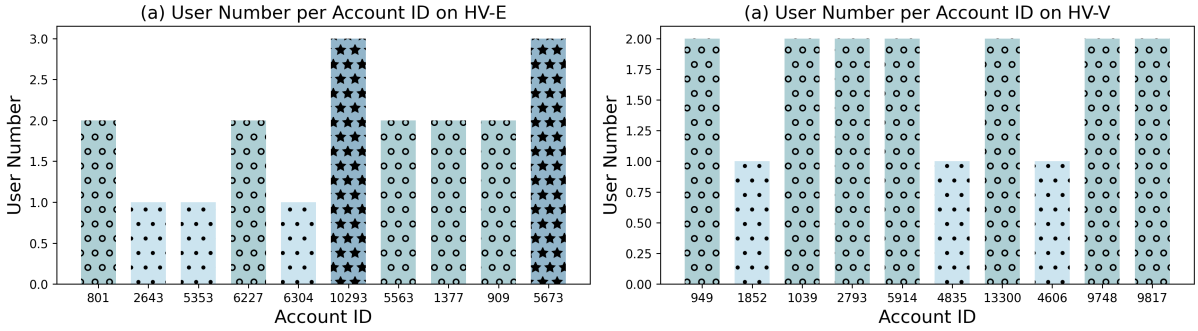

图 5. HV-E 和 HV-V 数据集上每个账户 ID 的潜在用户数量。它展示了通过推理过程为每个账户 ID 推断出的潜在用户数量。

7. 理论与实践意义

从理论上讲，我们提出的 DisenReason 通过引入一种新颖的两阶段推理框架，解决了现有共享账户序列推荐（SSR）方法的一项关键局限：假设每个账户中的潜在用户数量固定，而这一假设并不符合现实。在第一阶段，我们应用快速傅里叶变换，在频域中解耦混合序列，提取账户内不同的行为模式，再通过专家混合网络对其进行自适应融合，从而得到账户级推理枢轴。在第二阶段，我们提出渐进式残差推理机制，从账户级枢轴中迭代提取潜在用户，并根据语义相似度自适应地终止推理。这些设计共同使 DisenReason 为 SSR 领域作出有意义的贡献，尤其推动了共享账户场景下推理增强型推荐的发展。

在实际应用中，DisenReason 在账户共享普遍存在的现实场景中展现出明显的实用价值。我们在四个基准数据集上进行了广泛实验，涵盖真实场景和合成的共享账户场景，结果表明，与最先进的基线方法相比，该方法的性能始终显著提升，MRR@5 的相对提升最高可达 12.56%。该框架尤其擅长捕捉每个账户背后用户数量的动态变化，这也是流媒体等商业平台中常见的挑战

服务、电子商务网站和智能家居系统。通过自适应推断潜在用户数量并学习账户级表示，DisenReason 无需明确识别用户或手动配置，即可提供更加个性化且能感知上下文的推荐。本研究为从业者提供了切实可行的见解，助力其构建可扩展、稳健且以用户为中心的推荐服务，从而适应共享账户使用的实际情况。

8. 结论与未来工作

本文探讨了共享账户序列推荐（SSR）的核心挑战：如何准确推断并表示共享账户背后潜在用户数量及其行为模式的动态变化。现有方法通常假设潜在用户数量固定，但考虑到实际共享同一账户的用户数量会发生变化，这一假设并不现实。为此，我们提出了 DisenReason。该方法分两个阶段运行：（1）枢轴行为解耦，建立一个统一的枢纽，以反映共享账户的集体动态；（2）潜在用户渐进式残差推理，从该枢纽出发逐步推断潜在用户。这种两阶段推理能够有效识别潜在用户的数量，从而实现更精准、更个性化的推荐。实证实验验证了该框架的有效性，在多个数据集上均优于现有方法。

尽管 DisenReason 表现出良好的效果，但其固定带宽分割可能会忽略细粒度的行为边界，而两个阶段之间的参数耦合也会模糊任务目标。未来工作将研究自适应频率分解，以更好地保留行为完整性，并开发解耦架构或元学习机制，以区分全局聚合与个性化推理。这些方向旨在提升共享账户场景下潜在用户推断的准确性和可解释性。

CRediT 作者贡献声明

Jiawei Cheng： 本研究的概念构思、方法设计、软件开发、撰写。 **Min Gao：** 监督、撰写。 **Zongwei Wang：**监督、撰写。**XiaofeiZhu：** 监督。**ZhiyiLiu：**可视化。 **Wentao Li：** 监督。 **Wei Li：** 监督。 **Huan Wu：** 监督。

致谢

本论文得到国家自然科学基金（项目编号：62176028）资助。

利益冲突声明

作者声明不存在任何利益冲突。

数据可用性

如有需要，可提供数据。

参考文献

Acharya, T., Ray, A.K., 2005.《图像处理：原理与应用》。John Wiley & Sons。Ai, W., Zhang, F., Shou, Y., Meng, T., Chen, H., Li, K., 2025.《从图谱视角重新审视对话中的多模态情绪识别》，载于：AAAI 人工智能会议论文集，第11418–11426页。Baek, I., Yoon, M., Park, S., Lee, J., 2025.《Muffin：用于序列推荐的用户自适应频率滤波混合》。arXiv预印本 arXiv:2508.13670。Brigham, E.O., 1988.《快速傅里叶变换及其应用》。Prentice-Hall, Inc. Chen, H., Feng, Y., Liu, Z., Yao, W., Prabhakar, A., Heinecke, S., Ho, R., Mui, P., Savarese, S., Xiong, C., 等，2025.《语言模型是隐藏的推理者：通过自我奖励释放潜在推理能力》，2024b。arXiv预印本 arXiv:2411.04282。Chen, Z., Deng, Y., Wu, Y., Gu, Q., Li, Y., 2022.《迈向理解深度学习中的混合专家层》。神经信息处理系统进展 35，23049–23062。Cheung, M., Shi, J., Wright, O., Jiang, L.Y., Liu, X., Moura, J.M., 2020.《图信号处理与深度学习：卷积、池化和拓扑》。IEEE信号处理杂志 37，139–149。Deng, H., Xing, H., Matsuyama, K., Huang, Y., Hu, J., Wen, H., Xu, J., Chen, Z., Zhang, Y., Zeng, X., 等，2025.《Heterrec：用于可扩展序列推荐的异构信息变换器》，载于：国际ACM SIGIR信息检索研究与发展大会论文集，第3020–3024页。Du, X., Yuan, H., Zhao, P., Qu, J., Zhuang, F., Liu, G., Liu, Y., Sheng, V.S., 2023.《用于序列推荐的频率增强混合注意力网络》，载于：国际ACM SIGIR信息检索研究与发展大会论文集，第78–88页。

Duan, W., Liang, D., 2025.《面向精准共享账户营销的用户消歧学习：一种分层自注意序列推荐方法》。Knowledge-Based Systems 315，113328。Geiping, J., McLeish, S., Jain, N., Kirchenbauer, J., Singh, S., Bartoldson, B.R., Kailkhura, B., Bhatele, A., Goldstein, T., 2025.《通过潜在推理扩展测试时计算：一种循环深度方法》。arXiv预印本 arXiv:2502.05171。Guo, L., Tang, L., Chen, T., Zhu, L., Nguyen, Q.V.H., Yin, H., 2021.《DA-GCN：用于共享账户跨域序列推荐的领域感知注意图卷积网络》，载于：国际人工智能联合会议，第2483–2489页。Guo, L., Zhang, J., Chen, T., Wang, X., Yin, H., 2022a年。《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 35，7397–7411。Guo, L., Zhang, J., Tang, L., Chen, T., Zhu, L., Yin, H., 2022b年。《用于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 35，4002–4016。He, R., McAuley, J., 2016.《融合相似度模型与马尔可夫链，实现稀疏序列推荐》，载于：IEEE国际数据挖掘会议，IEEE，第191–200页。He, X., Deng, K., Wang, X., Li, Y., Zhang, Y., Wang, M., 2020.《LightGCN：简化并增强用于推荐的图卷积网络》，载于：国际ACM SIGIR信息检索研究与发展大会论文集，第639–648页。Hidasi, B., Karatzoglou, A., Baltrunas, L., Tikk, D., 2015.《基于循环神经网络的会话推荐》。arXiv预印本 arXiv:1511.06939。Jiang, W., Fan, Y., Tang, J., Li, X., Du, Y., Wang, X., 2026.《结合去噪Mamba的序列推荐分层长短期偏好建模》。Information Processing & Management 63，104425。Kang, W.C., McAuley, J., 2018.《自注意序列推荐》，载于：IEEE国际数据挖掘会议，第197–206页。Kingma, D.P., 2014.《Adam：一种随机优化方法》。arXiv预印本 arXiv:1412.6980。Li, H., Yang, Y., Zeng, J., Gao, M., Wen, J., 2026.《结合双重注意力与自适应掩码的多尺度Transformer，用于序列推荐》。Information Processing & Management 63，104318。Liu, X., Zhang, Z., Zhang, X., De Meo, P., Cherifi, H., 2025.《基于元学习的多监督器关联网络冷启动推荐》。Expert Systems with Applications 267，126204。Liu, Y., Xia, L., Huang, C., 2024.《SelfGNN：用于序列推荐的自监督图神经网络》，载于：第47届国际ACM SIGIR信息检索研究与发展大会论文集，第1609–1618页。Ma, M., Ren, P., Lin, Y., Chen, Z., Ma, J., Rijke, M.d., 2019.《π-net：用于共享账户跨域序列推荐的并行信息共享网络》，载于：第42届国际ACM SIGIR信息检索研究与发展大会论文集，第685–694页。Pan, L., Pan, W., Ming, Z., 2026.《通过多序列与多任务学习实现多域序列推荐》。Information Processing & Management 63，104426。Peintner, A., Mohammadi, A.R., Müller, M., Zangerle, E., 2025.《基于超图的序列推荐重复意图时间建模》，载于：ACM Web Conference论文集，第3809–3818页。Peng, S., Sugiyama, K., Mine, T., 2022.《少即是多：为推荐任务重新加权重要的谱图特征》，载于：国际ACM SIGIR信息检索研究与发展大会论文集，第1273–1282页。Pitas, I., 2000.《数字图像处理算法与应用》。John Wiley & Sons。Qiu, R., Huang, Z., Yin, H., Wang, Z., 2022.《用于解决序列推荐中表示退化问题的对比学习》，载于：国际网络搜索与数据挖掘会议论文集，第813–823页。Rao, Y., Zhao, W., Zhu, Z., Lu, J., Zhou, J., 2021.《用于图像分类的全局滤波网络》。神经信息处理系统进展 34，980–993。Rendle, S., Freudenthaler, C., Schmidt-Thieme, L., .《用于下一篮子推荐的个性化马尔可夫链分解》，载于：ACM Web Conference论文集。Shin, Y., Choi, J., Wi, H., Park, N., 2024.《超越自注意力的序列推荐注意力归纳偏置》，载于：AAAI 人工智能会议论文集，第8984–8992页。Sun, F., Liu, J., Wu, J., Pei, C., Lin, X., Ou, W., Jiang, P., 2019.《BERT4Rec：基于来自Transformer的双向编码器表示的序列推荐》，载于：ACM信息与知识管理国际会议论文集，第1441–1450页。Sun, W., Ma, M., Ren, P., Lin, Y., Chen, Z., Ren, Z., Ma, J., De Rijke, M., 2021.《用于共享账户跨域序列推荐的并行拆分合并网络》。IEEE知识与数据工程汇刊 35，4106–4123。Suvorov, R., Logacheva, E., Mashikhin, A., Remizova, A., Ashukha, A., Silvestrov, A., Kong, N., Goka, H., Park, K., Lempitsky, V., 2022.《利用傅里叶卷积实现分辨率鲁棒的大掩码图像修复》，载于：IEEE/CVF计算机视觉应用会议论文集，第2149–2159页。Tamkin, A., Jurafsky, D., Goodman, N., 2020.《透镜下的语言：多尺度语言表示的谱方法》。神经信息处理系统进展 33，5492–5504。Tang, J., Chen, X., Chen, W., Wu, J., Jiang, Y., Zheng, B., 2026.《用于序列推荐的并行潜在推理》。arXiv预印本 arXiv:2601.03153。Tang, J., Dai, S., Shi, T., Xu, J., Chen, X., Chen, W., Wu, J., Jiang, Y., 2025.《推荐前先思考：释放序列推荐的潜在推理能力》。arXiv预印本 arXiv:2503.22675。Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., J ones, L., Gomez, A.N., Kaiser, Ł., Polosukhin, I., 2017.《Attention Is All You Need》。神经信息处理系统进展 30。Verstrepen, K., Goethals, B., 2015.《面向共享账户的Top-N推荐》，载于：ACM推荐系统会议论文集，第59–66页。Wang, X., Yue, H., Guo, L., Guo, F., He, C., Han, X., 2025a.《结合对比聚类的共享账户推荐用户识别网络》。Information Processing & Management 62，104055。Wang, Z., Gao, M., Yu, J., Gao, X., Nguyen, Q.V.H., Sadiq, S., Yin, H., 2025b年。《无身份并非无风险：大语言模型驱动的智能体揭示无身份推荐系统中的风险》，载于：国际ACM SIGIR信息检索研究与发展大会论文集，第1902–1911页。Wang, Z., Gao, M., Yu, J., Sadiq, S., Yin, H., Liu, L., 2026.《图对比学习何时适得其反：推荐中的谱脆弱性与防御》。ACM Transactions on Information Systems 44，1–30。

Wang, Z., Yu, J., Gao, M., Yin, H., Cui, B., Sadiq, S., 2024年。揭示对比推荐系统易受投毒攻击的脆弱性，载于：知识发现与数据挖掘国际会议论文集，第 3311–3322 页。Wei, J., Wang, X., Schuurmans, D., Bosma, M., Xia, F., Chi, E., Le, Q.V., Zhou, D., 等, 2022年。思维链提示能够激发大语言模型的推理能力。《神经信息处理系统进展》35，24824–24837。Wu, Y., Meng, X., Hu, H., Zhang, J., Dong, Y., Lu, D., 2025。Affirm：采用自适应傅里叶滤波器的交互式 Mamba，用于长期时间序列预测，载于：AAAI 人工智能会议论文集，第 21599–21607 页。Xu, K., Qin, M., Sun, F., Wang, Y., Chen, Y.K., Ren, F., 2020年。在频域中学习，载于：IEEE/CVF 计算机视觉与模式识别会议论文集，第 1740–1749 页。Yang, Z., Qin, J., Zhang, D., Ma, J., Ji, P., 2024年。面向序列推荐的自适应频域数据增强。《IEEE Access》。Zhang, J., Zhao, Z., Li, C., Yu, Y., 2025a。轻量且细粒度：通过子空间对齐实现共享账户序列推荐的图胶囊卷积网络，载于：AAAI 人工智能会议论文集，第 13242–13250 页。Zhang, S., Wang, M., Wang, W., Gao, J., Zhao, X., Yang, Y., Wei, X., Liu, Z., Xu, T., 2025b。GLINT-RU：用于序列推荐系统的门控轻量智能循环单元，载于：知识发现与数据挖掘会议论文集，第 1948–1959 页。Zhang, X., Ding, H., Xie, F., Pan, L., Zi, Y., Wang, K., Zhang, H., 2025c。超越空间域：跨域增强傅里叶卷积助力单幅图像去雾，载于：AAAI 人工智能会议论文集，第 10221–10229 页。Zhao, C., Cai, W., Dong, C., Hu, C., 2024年。采用频率扩散调整的基于小波的傅里叶信息交互，用于水下图像复原，载于：IEEE/CVF 计算机视觉与模式识别会议论文集，第 8281–8291 页。Zhou, K., Yu, H., Zhao, W.X., Wen, J.R., 2022a年。序列推荐只需滤波增强型多层感知机，载于：ACM Web 会议论文集，第 2388–2399 页。Zhou, T., Ma, Z., Wen, Q., Wang, X., Sun, L., Jin, R., 2022b年。Fedformer：用于长期序列预测的频率增强分解变换器，载于：国际机器学习会议，PMLR，第 27268–27286 页。