arXiv:2603.07107v1 [cs.IR] 7 Mar 2026

基于半自回归生成和在线知识蒸馏的高效个性化重排序

Kai Cheng[1], Hao Wang[1(✉)], WeiGuo[2], Weiwen Liu[3], Yong Liu[2], Yawen Li[4],和Enhong Chen[1(✉)]

[1] 中国科学技术大学，中国合肥 {ck2020}@mail.ustc.edu.cn {wanghao3,cheneh}@ustc.edu.cn[2] 华为，中国上海 {guowei67,liu.yong6}@huawei.com[3] 上海交通大学，中国上海 wwliu@sjtu.edu.cn[4] 北京邮电大学，中国北京 warmly0716@126.com

摘要。 生成模型为多阶段推荐系统的最终阶段重排序提供了一种很有前景的范式，能够捕捉重排序列表中的物品间依赖关系。然而，将其实际部署仍面临两项关键挑战：（1）实现高生成质量与确保低延迟推理之间存在内在冲突，难以兼顾二者；（2）现有方法中用户特征与物品特征之间的交互不足。为应对这些挑战，我们提出一种用于重排序的新型**个**性化**半**自**回**归与在线知识**蒸**馏（PSAD）框架。在该框架中，教师模型采用半自回归生成器，以平衡生成质量与效率；同时，在联合训练过程中，将其排序知识在线蒸馏到轻量级评分网络中，从而实现实时、高效的推理。此外，我们提出用户画像网络（UPN），用于注入用户意图并建模兴趣动态，从而深化用户与物品之间的交互。在三个大规模公开数据集上进行的大量实验表明，PSAD在排序性能和推理效率方面均显著优于当前最先进的基线方法。

关键词： 推荐系统 · 重排序 · 生成模型。

1 引言

大规模在线平台广泛采用多阶段推荐系统（MRS），以提升用户体验并优化决策 [5,33–41]。这类系统通常包含三个阶段：召回、排序和重排序 [42,55–63], ，其中重排序阶段会对一小组候选物品进行优化，以生成最终

展示列表 [13,43]。与前述阶段不同，重排序必须兼顾物品的个体相关性及其相互依赖关系，才能生成整体最优的列表 [24]。如何有效地建模物品之间的交互，并理解多样化的用户兴趣，仍是该领域面临的关键挑战 [7]。

许多研究致力于重排序。早期研究采用判别式方法，根据物品各自的分数对其进行排序，主要建模候选集 [18,64] 内的关系。因此，这些方法往往忽视最终重排序列表中的关键上下文依赖关系，导致性能欠佳 [3,41]。

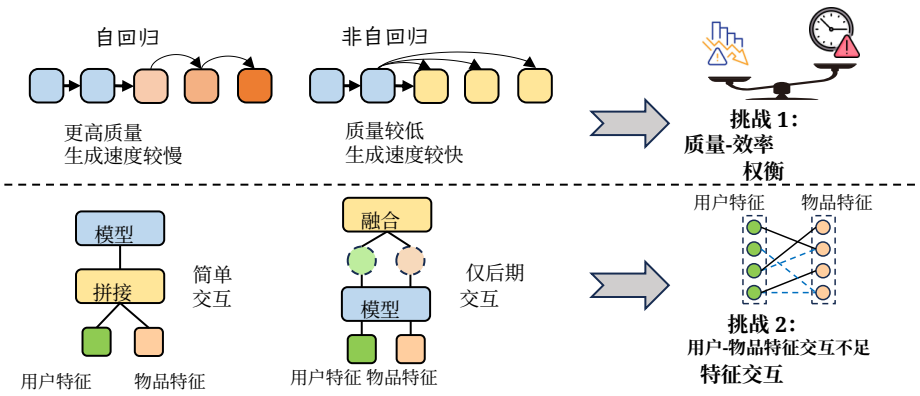

图 1. 生成式重排序方法面临的两项挑战。

近年来，生成模型因能够动态生成项目排列，同时显式建模重排序列表中的依赖关系 [2,16], ，从而优化最终展示列表，而受到广泛关注。这种方法包含自回归和非自回归两种策略 [45]：前者根据先前生成的物品依次生成物品 [3, 9], ，后者则不严格遵循顺序，直接生成整个序列，并关注全局项目关系 [20, 28]。

尽管取得了显著进展，生成式重排序方法仍面临若干关键挑战，如图1所示：**(1) 质量—效率权衡**：自回归模型通过细粒度序列建模实现了较高的生成质量，但由于采用逐步生成过程，存在推理速度慢和误差累积的问题 [28]。相比之下，非自回归模型能够进行高效的并行生成，但依赖较强的条件独立假设，导致输出缺乏连贯性 [22]。为缓解这些质量问题，研究人员通常采用迭代细化 [41]或两阶段范式 [28],，但这反过来又削弱了其原有的效率和实时能力。**(2)用户—项目特征交互不足**：尽管现有方法已探索个性化建模 [30, 42], ，但用户和项目特征之间的交互仍不充分。一些方法只是简单地拼接用户和

项目特征 [27], ，未能捕捉同一项目在不同用户视角下的语义变化；另一些方法仅在提取高层表示后才进行交互 [45], ，忽略了早期阶段的潜在联系，从而限制了对复杂用户兴趣模式的建模。

为解决这些问题，我们提出一种新颖的**P**个性化**S**半**A**自回归在线知识**D**蒸馏（**PSAD**）重排序框架。首先，针对挑战（1），我们引入统一的在线知识蒸馏框架。我们采用半自回归生成范式，其分块机制可减少误差累积，同时显著降低训练开销。为进一步降低推理延迟，我们进行在线知识蒸馏，通过共享编码器参数，从头联合训练轻量级评分网络与生成器。与需要预训练教师模型的离线方法不同，我们的方法使评分网络能够即时学习生成器的排序知识，而不会带来显著的蒸馏开销，从而在推理时以低延迟逼近高性能。其次，针对挑战（2），我们通过用户画像网络（UPN）将用户偏好深度注入模型。该网络包含两个组件：基于用户画像动态调整物品语义表示的个性化门控，以及用于捕捉独特用户兴趣衰减模式的个性化位置编码机制。综上所述，我们的贡献如下：

– 我们提出了 PSAD，从低延迟生成式重排序中用户-物品细粒度特征交互这一新颖视角出发，首次有效解决了生成式排序中的延迟和质量问题。– 我们设计了一种创新的在线蒸馏架构：半自回归教师模型通过分块生成实现高质量和高训练效率，同时在线将其知识蒸馏给轻量级学生模型，从而显著降低推理延迟。– 我们设计了 UPN，由个性化门控和个性化位置编码机制组成，以实现用户和物品特征的深度融合。– 大量实验表明，PSAD 在保持高质量排序性能的同时，显著降低了推理延迟。

2 相关工作

2.1 重排序方法

重排序方法通过优化整体排序质量来改进初始候选列表。早期的判别式方法，例如基于循环神经网络的 DLCM [1], 、基于 Transformer 的 PRM [27] 和 SetRank [26],，以及基于图神经网络的 IRGPR [23],，主要侧重于建模候选集中的上下文依赖关系。近年来，生成式重排序作为一种新范式应运而生，将任务视为“生成最优排列”的过程。Seq2Slate [3], 、CRUM [44],和 GRN [8] 等代表性方法采用自回归

或强化学习策略，直接生成优化后的项目序列；PIER [30] 利用哈希算法筛选候选项，而 NAR4Rec 等方法 [28] 则引入非自回归生成，以降低推理延迟。然而，这一新兴范式也面临新的挑战。现有方法通常难以兼顾生成质量与推理效率：自回归模型虽然能够生成高质量结果，但推理速度较慢；相反，非自回归模型效率很高，却常因独立性假设过强而缺乏连贯性，因此难以在实际部署中实现理想性能。

2.2 个性化重排序方法

从行为数据中挖掘用户意图已成为个性化重排序的重要方向。现有方法（如 PEAR [18] 和 MIR [45], ）对历史列表建模以捕捉用户偏好，但往往未能充分利用用户特征。一些模型（如 GRN [8] 和 PRM [27], ）只是拼接用户和物品特征，而另一些模型（如 MIR [45] 和 RAISE [21], ）仅在较后的隐藏层中进行用户—物品交互。这种延迟交互限制了模型及时捕捉复杂用户—物品关系的能力，进而制约了个性化建模的效果。

2.3 半自回归生成

为提高自回归模型的效率，自然语言处理领域的早期研究引入了半自回归建模，即每一步生成多个词元片段，而非单个词元 [32]。后续发展（如并行解码 [31] 和推测解码 [46],）进一步完善了这一思路。受这些进展启发，我们将半自回归生成机制应用于推荐系统的重排序阶段，使多个候选物品能够并行生成，从而提升整体性能。

3 预备知识

定义*1.*（重排序问题）重排序阶段通常定义如下：给定用户 u、从前一推荐阶段获得的候选序列 C_u 、用户近期的交互历史 H_u以及用户的画像特征 $\mathcal{P}_u$（例如年龄、性别等）。 C_u 或 H_u 集合中的每个物品都由稀疏特征（如类别 ID、品牌 ID 等）和稠密特征（如价格、分数等）刻画。重排序问题旨在学习一个映射函数 $\mathcal{F}$，使得 $\mathcal{F}(C_u, H_u, \mathcal{P}_u) \rightarrow R_u$，其中 R_u 是呈现给用户的重排序列表，而 $R_u \subseteq C_u$。 H_u 的长度记为 N，C_u记为 M， R_u记为 T，通常满足 $T \leq M$。

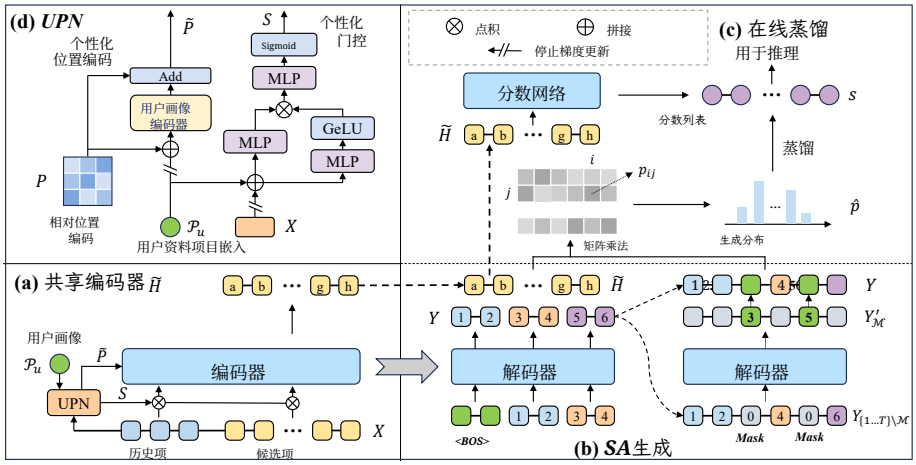

图 2。 PSAD 的整体框架及其子模块。

定义 ***2.***（生成式重排序）生成式重排序模型旨在通过直接对其条件概率进行建模，找到最优序列 R_u 。目标是生成在给定用户上下文时似然最大的列表：$R_u^* = \arg\max_{R_u \in \mathcal{P}(C_u)} p(R_u | C_u, H_u, \mathcal{P}_u)$，其中 $\mathcal{P}(C_u)$ 表示候选集 C_u 中所有有效物品排列构成的空间。对 $p(R_u \mid \cdot)$ 的不同建模假设会产生多种生成范式，例如自回归或非自回归方法。

4 方法论

现有的生成式重排序模型通常难以平衡生成质量与推理效率，同时在个性化建模方面也缺乏足够的深度。为应对这些挑战，我们提出了 PSAD，其整体架构如图 2 所示。本节将详细介绍其核心组件：首先，共享编码器（图 2（a））处理所有输入序列，如第 4.1 节所述。接下来，我们通过半自回归生成（图2（b））和在线蒸馏（图 2（c））解决质量与效率之间的权衡，具体内容见第4.2 节。随后，我们引入用户画像网络（UPN）（图 2（d）），以实现深度个性化，相关讨论见第4.3 节。最后，第 4.4 节介绍 PSAD 的推理过程。

4.1 编码器

嵌入层 根据定义 *1*，对于用户历史序列 H_u 或候选集 C_u中的每个物品 v ，该物品的第 i个稀疏特征会通过相应的嵌入表映射为表示 $e_{v,\,i}$ 。随后，我们将所有稀疏特征的嵌入与物品的稠密特征拼接，形成最终的物品嵌入：

$x_v = [e_{v,1} \oplus \cdots \oplus e_{v,k} \oplus$

$x_d^v] \in \mathbb{R}^{d_x}$，其中 k 表示稀疏特征的数量， x_d^v 表示稠密特征向量。算子 $\oplus$ 表示向量拼接。将所有物品嵌入 x_v堆叠后，我们得到输入物品矩阵 $X \in \mathbb{R}^{(N+M)\times d_x}$。类似地，用户 u 的嵌入向量表示为 $\mathcal{P}_u \in \mathbb{R}^{d_u}$.

共享编码器 为了更好地捕捉物品之间的关系，我们采用自注意力结构，注意力得分矩阵的计算方式为:

$$A^l = \frac{\mathrm{Softmax}((X^l W_Q^l)(X^l W_K^l))}{\sqrt{d_x}} + P^l, \tag{1}$$

其中 l 表示模型中的第 l层， W_Q 表示可学习参数 $\in \mathbb{R}^{d_x \times d_x}$，其余同理。矩阵 P^l 是可学习参数，其中$P_{i,j}^l$ 表示第 i个位置和第j个位置的位置编码值。随后将注意力得分与注意力值相乘，并经过前馈层，得到编码器的输出:

$$H^l = A^l(X^l W_V^l), \quad \tilde{H}^l = \mathrm{FFN}(H^l). \tag{2}$$

编码器堆叠多个相同的层，其中每一层的输入 X^l 是上一层的输出 $\tilde{H}^{l-1}$ 。

4.2 生成器与在线蒸馏

半自回归生成 在编码阶段之后，我们使用生成器对候选集进行重排序。为克服自回归模型与非自回归模型的固有局限，我们设计了一种半自回归生成方案，通过减少生成步骤的数量来缓解误差累积并提高生成效率，同时保留自回归依赖以捕捉序列关系。从概念上讲，它类似于指针网络 [3], ，其中生成查询向量以从候选集中选择物品。在实践中，生成器在每个迭代步骤并行构建包含 K 个物品的块，直至形成完整序列。

具体过程如下：设目标结果长度为 T，块大小为 K，第 b 个块的位置索引定义为 $\mathcal{I}_b = \{(b-1)K+1, \ldots\ldots, \min(bK, T)\}$. 对于每个块，我们根据此前生成的上下文，同时生成 K 个词元:

$$Y_{\mathcal{I}_b}^l = \mathrm{CrossAttn}(H^l, Y_{<\mathcal{I}_b}^l), \tag{3}$$

其中，CrossAttn 表示模型的交叉注意力， $Y_{<\mathcal{I}_b}$ 表示当前块之前的词元所产生的结果。为减少每个并行生成块内部的不一致性，我们采用上下文增强步骤，通过掩码并细化的范式来优化完整序列 Y。我们随机掩码一部分词元 $\mathcal{M}$，其中 $|\mathcal{M}| = \gamma$，然后根据未掩码的上下文条件，用预测结果更新这些词元:

$$Y'_{\mathcal{M}} = \mathrm{CrossAttn}(H^l, Y_{\{1..T\}\setminus\mathcal{M}}), \quad Y \leftarrow Y_{\{1..T\}\setminus\mathcal{M}} \cup Y'_{\mathcal{M}}. \tag{4}$$

生成概率矩阵由生成序列表示与候选集的隐藏向量相乘得到：

$$p_{ij} = \text{Sigmoid}(\tilde{H}_i^L \cdot Y_j^L), \tag{5}$$

其中， L 表示层的总数。矩阵元素 p_{ij} 表示候选集中的第 i个候选项位于重排序列表中第 j位的概率。然后，我们计算生成损失：

$$\mathcal{L}_{gen} = \sum_j \omega_j (\sum_i (-\hat{y}_i \log p_{ij}) + \max\{0, 1 - \min_{i:\hat{y}_i=1} p_{ij} + \max_{i:\hat{y}_i=0} p_{ij}\}), \tag{6}$$

其中，$\hat{}y_i$ 表示真实值，$\hat{}y_i$ 在第 i个候选项具有正标签时为 1，否则为 0。我们的生成损失结合了用于衡量逐点准确率的交叉熵项和用于衡量列表排序顺序的合页损失，并通过受 DCG 启发的项$\omega_j = \frac{1}{\log(j+1)}$加权，以优先考虑靠前的位置。

在线知识蒸馏 为了进一步降低推理过程中的计算负担，我们提出了一个统一的在线知识蒸馏框架。该框架包含一个轻量级评分网络作为学生模型，并与先前介绍的生成器（作为教师模型）联合训练。评分网络为每个候选项i 计算分数 s_i ，并使用标准交叉熵损失进行监督：

$$s_i = \text{Sigmoid}(\text{MLP}(\tilde{H}_i^L)), \quad \mathcal{L}_{scorer} = -\sum_i \hat{y}i \log s_i. \tag{7}$$

与依赖预训练教师模型的离线蒸馏方法不同，我们采用即时蒸馏，将生成器的排序知识迁移到学生模型中，并使用指数衰减加权方案将生成器的概率矩阵汇总为每个项目的目标分数 $\hat{}p_i$ ：

$$\tilde{p}ij = \frac{\exp(pij)}{\sum_k \exp(p_{kj})}, \quad \hat{p}i = \frac{\sum_j \tilde{pij} \cdot e^{-j}}{\sum_j e^{-j}}, \tag{8}$$

随后，为了更有效地衡量教师与学生输出分布之间的一致性，我们采用卡尔曼-莱布勒散度作为蒸馏损失：

$$\mathcal{L}_{Distillation} = \text{KL}\Big(\text{Softmax}(\hat{p}/\tau) \parallel \text{Softmax}(s/\tau)\Big), \tag{9}$$

其中， τ是用于平滑概率分布的温度。最后，总训练损失由协同训练过程中的各项损失组成：

$$\mathcal{L} = \mathcal{L}_{gen} + \mathcal{L}_{scorer} + \alpha \cdot \mathcal{L}_{Distillation}\ , \tag{10}$$

其中， α 是用于平衡蒸馏损失的超参数。通过优化这一目标，学生模型能够在推理过程中高效地模拟教师模型复杂的排序偏好，从而在保持低延迟推理的同时实现高生成质量。

4.3 用户画像网络

个性化门控以往的重排序方法通常将物品编码为固定嵌入。然而，由于用户兴趣具有多样性，物品表示应根据用户特定特征动态调整。为此，我们设计了一个个性化门控单元，将用户画像信息融入物品表示，同时保留原始物品特征，从而生成个性化物品嵌入。其工作原理如下：

$$\mathcal{G}_1 = \mathrm{MLP}_1(\oslash X, \mathcal{P}_u), \quad \mathcal{G}_2 = \mathrm{GeLU}(\mathrm{MLP}_2(\oslash X, \mathcal{P}_u)), \tag{11}$$

其中，MLP 指全连接层，GeLU 是一种非线性激活函数。 $\oslash$ 表示停止梯度操作，这可确保该模块仅优化用户画像，从而加快训练过程中的收敛速度。随后，我们计算物品-用户对的激活表示与非激活表示之间的交互，以生成门控信号：

$$S = \mathrm{Sigmoid}(\mathrm{MLP}(\mathcal{G}_1 \odot \mathcal{G}_2)), \quad \hat{X} = S \odot X, \tag{12}$$

其中， $\odot$ 表示哈达玛积。门控信号 S 作用于物品嵌入 X，并与投影后的用户画像结合，生成个性化表示 $\hat{X}$，该表示作为公式（1）的输入。

个性化位置编码在公式（1）中，相对位置编码 P^l 假设所有用户都具有固定的兴趣衰减模式。为实现个性化，我们提出一种位置自适应方案，使模型能够根据用户画像动态调整通用位置偏置 P^l_{ij} 。具体而言，我们将用户偏好 $\mathcal{P}_u$ 与通用位置关系 P^l_{ij}融合，为每个位置对生成自适应偏置。将该偏置加到原始编码上，即可得到个性化位置编码 $\hat{P}^l$：

$$\hat{P}^l_{ij} = P^l_{ij} + \mathrm{Tanh}(\mathrm{MLP}(\oslash \mathcal{P}_u \oplus P^l_{ij})). \tag{13}$$

这使模型能够学习用户特定的兴趣动态，而非统一的时间衰减模式。

4.4 模型推理

在推理过程中，生成器根据公式（5）计算概率分布，并通过束搜索生成候选序列，随后由PRM对这些序列进行评分，以选出得分最高的序列。相比之下，评分网络直接根据公式（7）分配分数，并对物品进行排序，以选出前 T 个候选。显然，通过评分网络进行推理更为高效，在缓解重排序过程中的延迟方面发挥着关键作用。

表 1. 数据集统计。

数据集	#用户	#物品	#记录
Ad	1.06×10^6	8.27×10^5	2.04×10^6
PRM Public	7.44×10^5	7.25×10^6	1.44×10^7
Avito	1.32×10^6	2.36×10^7	5.36×10^7

5 实验

5.1 实验设置

数据集 为确保所提方法具有广泛适用性，我们在公开数据集上进行了大量实验，包括电子商务重排序数据集和广告数据集。

– **广告**[5]：该数据集记录了用户与广告之间的交互，包含 9 个用户特征（例如 ID、年龄和职业）以及 6 个物品特征（例如 ID、广告活动和品牌）。根据用户与广告交互的时间戳，我们将每位用户的记录转换为排序列表。五分钟内发生交互的物品会被归入同一个列表。
– **PRM Public**[6]：该数据集包含 3 个用户画像特征、5 个类别特征和 19 个稠密特征。我们将最后一个交互列表作为目标，而此前列表中的交互则用于构建历史列表。– **Avito**[7]：该数据集由多个用户搜索日志及元数据构成。对于每位用户，最近搜索页面上的广告用作预测目标，而此前的页面则作为历史行为。

在数据处理方面，我们采用了与以往研究类似的方法 [14,15,19,24,25,29,45],：移除交互记录少于四条的用户和物品，并仅保留至少有一次点击的用户，以确保交互数据充足，从而准确捕捉用户偏好。处理后数据集的详细统计信息汇总于表1。

评估指标 重排序涵盖更多样化的目标，例如效用 [1]，多样性 [4]，和公平性 [12]。本研究聚焦于效用驱动的重排序，我们采用广泛使用的NDCG@K和MAP@K [17,45,50–54]。由于现实应用中重排序后的物品数量通常为数十个 [27,42]，，我们将广告和PRM Public数据集的重排序结果列表长度设为10，并相应设置 $K = 5$ 和 10。由于Avito数据集中的候选集仅包含5个物品，我们为该数据集设置 $K = 5$ [28]。

[5] https://tianchi.aliyun.com/dataset/56[6]
https://github.com/rank2rec/rerank[7]
https://www.kaggle.com/c/avito-context-ad-clicks/data

基线方法 我们将所提出的方法与6种先进的重排序方法进行比较。我们选取miDNN、DLCM和PRM作为代表不同结构的典型基线，并选取Seq2Slate、CRUM、PIER和NAR4Rec作为生成模型的典型基线。具体细节如下：

– **miDNN** [64]：miDNN 通过全局特征扩展，提取输入排序列表中物品之间的相互影响。– **DLCM** [1]：DLCM 首先使用门控循环单元对整个排序列表进行顺序编码，生成物品表示。– **PRM** [27]：PRM 使用自注意力对任意一对物品之间的相互影响以及用户偏好进行建模。– **Seq2Slate** [3]：Seq2Slate 基于循环神经网络指针网络架构，通过顺序预测下一个物品来生成重排序列表。– **CRUM** [44]：CRUM 使用效用评估器指导物品对交换，从而在成对重排序中实现较高效用。– **PIER** [30]：PIER 使用哈希算法，根据用户兴趣从完整排列中选出前k个候选项。随后，生成器与评估器联合训练，以生成更优的排列。– **NAR4Rec** [28]：NAR4Rec 使用非自回归生成模型来减轻推理偏差并提高效率。

超参数设置 我们使用 Adam 作为优化器来实现我们的模型及基线方法，批大小为 256。我们将用户最近点击的 50 个物品作为其历史。根据不同场景，广告的最大候选集长度设为 20，学习率为 1e-4；PRM Public 的最大候选集长度设为 30，学习率为 3e-5；Avito 的最大候选集长度设为 5，学习率为 3e-5。稀疏特征的嵌入维度设为 16。我们的源代码将在论文发表后公开。

5.2 整体性能对比

对于所有实验，我们首先训练生成器和评分网络。参见第 4.4 节，对于我们的方法，仅使用训练好的生成器进行推理的变体记为 **PSAD-G**，而联合训练生成器与评分器并通过在线蒸馏评分网络进行推理的变体记为 **PSAD-S**。

性能比较 本节将 PSAD 与判别式和生成式重排序基线进行比较，结果如表 2所示。我们还进行了 Wilcoxon符号秩检验 [6]，以评估 PSAD 与基础模型之间差异的统计显著性。我们得到以下观察结果：

(1) 生成式范式优于判别式范式。即使是较早的生成模型 Seq2Slate，也胜过 PRM 等强大的判别式基线，这凸显了我们所研究问题的重要性。

表2. 所有方法在 NDCG@K 和 MAP@K（K=5，10）上的总体性能比较。（p值 < 0.05）

数据集	Ad				PRM Public				Avtio	
指标	N@5	N@10	M@5	M@10	N@5	N@10	M@5	M@10	N@5	M@5
miDNN	0.6819	0.6952	0.6025	0.6063	0.2620	0.3341	0.2842	0.2954	0.6737	0.6838
DLCM	0.6857	0.6989	0.6064	0.6100	0.2664	0.3395	0.2918	0.3023	0.6912	0.7057
PRM	0.6872	0.7015	0.6080	0.6117	0.2689	0.3430	0.2937	0.3042	0.7047	0.7174
Seq2Slate	0.6916	0.7062	0.6119	0.6155	0.2709	0.3449	0.2959	0.3061	0.7245	0.7360
CRUM	0.6899	0.7037	0.6084	0.6112	0.2703	0.3445	0.2952	0.3056	0.7110	0.7266
PIER	0.6940	0.7070	0.6123	0.6158	0.2694	0.3423	0.2941	0.3038	0.7156	0.7292
NAR4Rec	0.6965	0.7101	0.6151	0.6188	0.2701	0.3455	0.2968	0.3071	0.7315	0.7462
PSAD-G	**0.7038**	**0.7184**	**0.6216**	**0.6255**	**0.2762**	**0.3528**	**0.3039**	**0.3136**	**0.7427**	**0.7561**
PSAD-S	0.6962	0.7091	0.6146	0.6185	0.2717	0.3464	0.2985	0.3079	0.7285	0.7396

通过利用生成式方法对最终重排序列表中物品之间的相互影响进行建模，我们能够更有效地捕捉上下文依赖关系，并取得更优的排序性能。

(2) 对候选项之间全局关系进行建模的方法（如 PRM）优于逐点方法 miDNN 和单向方法 DLRM，这凸显了我们采用注意力机制捕捉物品间依赖关系的有效性。

(3) 生成模型 PSAD-G 在所有数据集上的表现始终优于其他生成式方法，展现出强大的有效性和泛化能力。这归功于半自回归生成策略与上下文增强模块，两者协同提升了生成质量。此外，所提出的用户画像网络能够高效利用用户表征，增强个性化建模。

(4) 评分模型 PSAD-S 优于所有判别式基线，且表现与最强的生成式基线 NAR4Rec 不相上下。这证实了我们的在线知识蒸馏框架能够有效地将生成模型的物品分布压缩到轻量级评分网络中。此外，后续的效率比较验证了该框架在训练和推理阶段均具有更高的效率。

效率比较遵循先前的工作 [10, 11, 28, 47–49]，我们测量平均训练和推理时间，并在 PRM Public 数据集上使用不同批次大小，将我们的模型与基线模型进行比较，如表3所示：

(1) 与判别式模型相比，生成模型的训练和推理耗时显著更长，这验证了我们的研究动机：现有生成式方法往往难以兼顾性能与效率，因而带来大量计算开销。

表3. PSAD 与基线方法在 PRM Public 数据集上的训练和推理时间对比。比较在不同批次大小下进行，时间通过对 10 个步骤的结果取平均值计算。时间单位为秒。

批次大小	64		128		256	
模型	训练(↓)	推理(↓)	训练(↓)	推理(↓)	训练(↓)	推理(↓)
miDNN	0.0895	0.0764	0.1425	0.1256	0.2132	0.1893
DLCM	0.2799	0.1497	0.4301	0.2409	0.6827	0.3940
PRM	0.1238	0.1014	0.1852	0.1360	0.2806	0.2037
Seq2Slate	0.3142	0.2176	0.5114	0.3993	0.8384	0.5873
CRUM	0.2021	0.1589	0.3185	0.2850	0.4415	0.3048
PIER	0.2428	0.2247	0.3608	0.3394	0.5482	0.4735
NAR4Rec	0.1903	0.1356	0.2904	0.2215	0.4649	0.3572
PSAD-G	0.1834	0.1568	0.2860	0.2376	0.4931	0.4239
PSAD-S	0.1897	0.0801	0.2943	0.1290	0.5128	0.2161

表 4. PSAD-G 的消融分析

数据集	Ad		PRM Public			Avito
指标	N@10	M@10	N@10	M@10	N@5	M@5
无半自回归	0.7095	0.6192	0.3455	0.3054	0.7145	0.7295
无交叉熵	0.7133	0.6220	0.3482	0.3096	0.7231	0.7360
$w/osace$	0.7042	0.6139	0.3441	0.3052	0.7103	0.7217
无 ***ppe***	0.7168	0.6248	0.3523	0.3128	0.7384	0.7546
无***pg***	0.7136	0.6224	0.3507	0.3110	0.7402	0.7543
PSAD-G	**0.7184**	**0.6255**	**0.3528**	**0.3136**	**0.7427**	**0.7561**

(2) PSAD 的训练效率显著高于自回归生成模型 Seq2Slate，同时与 NAR4Rec 和 CRUM 等非自回归模型不相上下。这证实了 PSAD 所采用的半自回归生成策略能够有效保持较高的生成质量，同时避免引入过高的训练成本。

(3) PSAD-S 的推理速度快于所有生成式基线，甚至超过了 PRM 等一些复杂的判别式模型。同时，与 PSAD-G 相比，其总体训练成本仅略有增加。这些结果验证了我们共享编码器在线蒸馏框架的有效性：该框架以极低的额外训练成本引入了一个轻量级评分模型，同时实现了极低的推理延迟。

5.3 消融实验

我们设计了模型的多个变体，以研究所提方法中各个组件的有效性，并在公开数据集上开展了一系列实验。无半自回归变体（无半自回归）表示

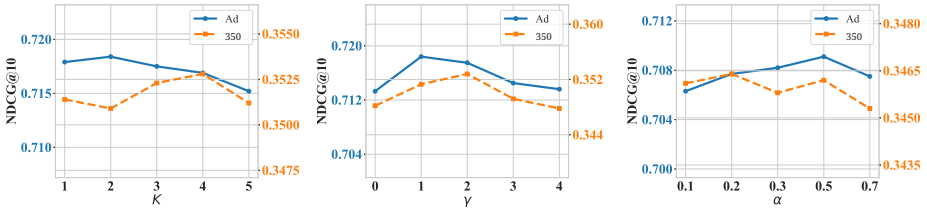

图 3. 超参数性能

我们一次性生成所有物品，而不采用分块生成策略；无上下文增强变体（无 ***ce***）表示移除上下文增强过程；无半自回归和上下文增强变体（无 ***sace***）表示同时移除半自回归生成和上下文增强模块；无个性化位置编码变体（无 ***ppe***）表示移除用于建模兴趣衰减的个性化相对位置编码；无个性化门控变体（无 ***pg***）表示移除个性化门控网络。

上述变体与 PSAD 在三个公开数据集上的比较结果见表 4：（无半自回归）表明，与单次生成相比，分块生成能更好地保留生成序列中的依赖关系，验证了我们提出的半自回归生成方法的有效性。（无上下文增强）表明，上下文增强有助于提升生成序列的局部连贯性和块间一致性。（无半自回归及上下文增强）表明，半自回归生成与上下文增强相结合能够带来更好的性能。（无个性化位置编码）揭示了个性化位置编码在建模个性化兴趣衰减方面的重要性，这有助于在排序列表中更准确地定位用户意图。（无***pg***）证实，个性化门控通过根据用户画像动态调整物品特征，提升了用户-物品对齐效果。

5.4 超参数研究

如图3所示，我们在两个数据集上分析了PASD的关键超参数，包括并行生成块大小（K）、随机掩码的数量（γ）以及蒸馏权重（α）。对于块大小 K，整体性能呈现先升后降的趋势。较小的 K 无法缓解逐项生成带来的误差累积，而过大的 K会因过强的独立性假设损害序列的内部一致性。对于随机掩码数量 γ，模型在 $\gamma = 1$ 或2时取得最优性能，而更大的取值会破坏已有的合理序列结构。对于蒸馏权重 α，PSAD-S分别在 $\alpha = 0.5$ 和0.2 时于相应数据集上表现最佳。由于 α 控制着来自真实标签的监督与来自生成器的分布引导之间的权衡，次优取值会打破这一平衡并导致更差的结果。

表5. 不同蒸馏方法在性能（NDCG@10）和训练时间方面的比较。批大小设为256，时间为10个训练步骤的平均值。时间单位为秒。

数据集	Ad		PRM	
教师模型	N@10(↑)	训练(↓)	N@10(↑)	训练(↓)
AR（在线）	0.7078	0.4896	0.3434	0.7372
NAR（在线）	0.7046	0.3004	0.3429	0.4165
SAR（离线）	0.7083	0.6547	0.3481	0.8933
SAR（在线）	0.7091	0.3752	0.3464	0.5128

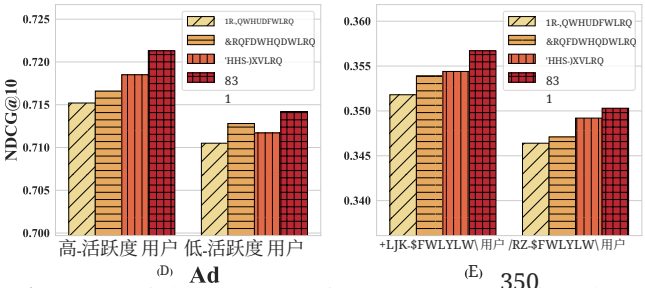

图4。不同活跃度水平的用户序列中物品–用户特征交互机制的性能比较。

5.5 深入分析

蒸馏方法分析为验证采用半自回归生成器对得分网络进行在线蒸馏的必要性，我们比较了不同教师模型的影响，包括自回归（AR）、非自回归（NAR）和半自回归（SAR），以及离线蒸馏对学生模型最终性能的影响。根据表5中的结果，我们得出以下结论：（1）使用半自回归模型作为教师可取得最佳蒸馏效果，同时相比全自回归模型所需训练时间显著更少，从而证实了采用半自回归生成器作为教师的合理性。（2）传统的两阶段离线蒸馏耗时远长于我们的在线方法。更重要的是，在线蒸馏使学生能够从持续改进的教师而非静态知识中学习，从而使学生模型获得相当甚至更优的性能。

用户-物品交互分析 为评估 UPN 模块的个性化建模能力，我们根据交互序列长度，将排名前 20% 的用户定义为高活跃用户，其余用户定义为低活跃用户。我们在两个数据集上比较了四种交互策略的性能：无交互、拼接 [27], 后期融合 [45],和 UPN。如图 4所示，结果表明，UPN 的表现始终优于其他交互策略，尤其为高活跃用户带来了显著提升。

活跃用户。这表明，当有足够的个性化信号时，UPN 的动态多维交互机制能够更有效地捕捉用户特征，并将其转化为排序性能的显著提升。

6 结论

本研究探讨了现有生成式重排序方法面临的两大挑战：高生成质量与低推理延迟之间的权衡，以及用户特征与物品特征之间交互不足。为解决这些问题，我们提出了一种新颖的重排序框架——采用在线知识蒸馏的个性化半自回归（PSAD），兼顾质量、效率与个性化。具体而言，强大的半自回归教师模型 PSAD-G 通过分块生成机制和提出的用户画像网络（UPN），确保获得高质量且深度个性化的排序知识。与此同时，轻量级学生网络 PSAD-S 通过在线知识蒸馏实时学习这些知识，从而实现快速、高效的推理。在三个大规模数据集上开展的大量实验表明，PSAD-G 在排序性能方面树立了新的基准，而 PSAD-S 则在保持准确率相当的同时显著降低了推理延迟。这些结果验证了 PSAD 在弥合生成质量与推理效率之间差距的同时，提升个性化重排序性能的有效性。未来，我们将进一步探索并优化蒸馏机制，以增强两种建模范式之间的知识迁移与泛化能力。

参考文献

1. Ai, Q., Bi, K., Guo, J., Croft, W.B.：用于排序优化的深度列表级上下文模型学习。载于：第41届国际ACM SIGIR信息检索研究与发展大会。第135–144页（2018） 2. Ai, Q., Wang, X., Bruch, S., Golbandi, N., Bendersky, M., Najork, M.：使用深度神经网络学习分组多变量评分函数。载于：2019年ACM SIGIR信息检索理论国际会议论文集。第85–92页（2019） 3. Bello, I., Kulkarni, S., Jain, S., Boutilier, C., Chi, E., Eban, E., Luo, X., Mackey, A., Meshi, O.：Seq2slate：利用循环神经网络进行重排序与列表优化。arXiv预印本 arXiv:1810.02019（2018） 4. Carraro, D., Bridge, D.：利用大语言模型重排序以提升推荐多样性。ACM推荐系统汇刊（2024） 5. Deng, J., Wang, S., Cai, K., Ren, L., Hu, Q., Ding, W., Luo, Q., Zhou, G.：OneRec：通过生成式推荐系统和迭代偏好对齐统一召回与排序。arXiv预印本 arXiv:2502.18965（2025） 6. Derrick, B., White, P.：比较针对单个李克特题项的两个样本。《国际数学与统计学杂志》 **18**(3)，1–13（2017） 7. Feng, Y., Gong, Y., Sun, F., Ge, J., Ou, W.：从排列视角重新审视推荐系统。arXiv预印本 arXiv:2102.12057（2021）

8. Feng, Y., Hu, B., Gong, Y., Sun, F., Liu, Q., Ou, W.：GRN：用于上下文推荐的生成式重排序网络。arXiv预印本 arXiv:2104.00860（2021） 9. Gong, X., Feng, Q., Zhang, Y., Qin, J., Ding, W., Li, B., Jiang, P., Gai, K.：移动设备上的实时短视频推荐。载于：第31届ACM信息与知识管理国际会议论文集。第3103–3112页（2022） 10. Gu, H., Li, D., Dong, K., Zhang, H., Lv, H., Wang, H., Lian, D., Liu, Y., Chen, E.：Rapid：通过写作规划与信息发现实现高效的检索增强长文本生成。载于：计算语言学协会：ACL 2025论文集。第16742–16763页（2025） 11. Guo, W., Wang, H., Zhang, L., Chin, J.Y., Liu, Z., Cheng, K., Pan, Q., Lee, Y.Q., Xue, W., Shen, T., 等：拓展新前沿：大型推荐模型的洞见。arXiv预印本 arXiv:2412.00714（2024） 12. Han, F., Wang, S., Zhao, J., Wu, R., Rui, X., Wang, Z.：基于去偏多图表示的公平推荐重排序。载于：高级数据挖掘与应用国际会议。第168–182页。Springer（2023） 13. Hron, J., Krauth, K., Jordan, M., Kilbertus, N.：关于两阶段推荐系统中的组件交互。神经信息处理系统进展**34**，2744–2757（2021） 14. Huang, Y., Zhang, R., He, X., Zhi, X., Wang, H., Li, X., Xu, F., Liu, D., Liang, H., Li, Y., 等：ChemEval：面向大语言模型的全面多层次化学评估。arXiv预印本 arXiv:2409.13989（2024） 15. Huang, Y., Zhang, R., Wang, Q., Lu, C., Gao, Y., Wu, Y., Hu, Y., Zhi, X., Liu, G., Li, X., 等：SelfAug：通过分布自对齐缓解检索增强生成中的灾难性遗忘。arXiv预印本 arXiv:2509.03934（2025） 16. Huzhang, G., Pang, Z.J., Gao, Y., Liu, Y., Shen, W., Zhou, W.J., Lin, Q., Da, Q., Zeng, A.X., Yu, H., 等：速卖通学习排序：无需上线即可最大化在线模型性能。IEEE知识与数据工程汇刊**35**(2)，1214–1226（2021） 17. Järvelin, K., Kekäläinen, J.：基于累积增益的检索技术评估。ACM信息系统汇刊（TOIS）**20**(4)，422–446（2002） 18. Li, Y., Zhu, J., Liu, W., Su, L., Cai, G., Zhang, Q., Tang, R., Xiao, X., He, X.：PEAR：用于推荐的上下文化Transformer个性化重排序。载于：2022年万维网会议伴随论文集。第62–66页（2022） 19. Liang, S., Lv, H., Wen, Z., Wu, Y., Zhang, Y., Wang, H., Liu, Y.：利用检索增强生成进行自适应模式感知事件抽取。计算语言学协会论文集：EMNLP（2025） 20. Lin, X., Chen, X., Wang, C., Shu, H., Song, L., Li, B., Jiang, P.：用于推荐重排序的离散条件扩散。载于：2024年ACM万维网会议伴随论文集。第161–169页（2024） 21. Lin, Z., Zang, S., Wang, R., Sun, Z., Senthilnath, J., Xu, C., Kwoh, C.K.：对自注意力进行注意：利用动态Transformer编码器进行意图感知重排序，以实现推荐。IEEE知识与数据工程汇刊**35**(8)，7782–7795（2022） 22. Liu, S., Cai, Q., He, Z., Sun, B., McAuley, J., Zheng, D., Jiang, P., Gai, K.：用于列表式推荐的生成流网络。载于：第29届ACM SIGKDD知识发现与数据挖掘大会论文集。第1524–1534页（2023） 23. Liu, W., Liu, Q., Tang, R., Chen, J., He, X., Heng, P.A.：结合物品关系的电子商务个性化重排序。载于：第29届ACM信息与知识管理国际会议论文集。第925–934页（2020）

24. Liu, W., Xi, Y., Qin, J., Sun, F., Chen, B., Zhang, W., Zhang, R., Tang, R.: 多阶段推荐系统中的神经重排序：综述. arXiv预印本 arXiv:2202.06602 (2022) 25. Pan, Q., Wang, H., An, G., Zhang, L., Guo, W., Liu, Y.: 基于多嵌入方法与专家混合重探可扩展序列推荐. arXiv预印本 arXiv:2510.25285 (2025) 26. Pang, L., Xu, J., Ai, Q., Lan, Y., Cheng, X., Wen, J.: SetRank: 学习用于信息检索的置换不变排序模型. 载于：第43届国际ACM SIGIR 信息检索研究与发展大会论文集 . 第 499–508 页 (2020) 27. Pei, C., Zhang, Y., Zhang, Y., Sun, F., Lin, X., Sun, H., Wu, J., Jiang, P., Ge, J., Ou, W., 等: 面向推荐的个性化重排序. 载于：第13届ACM推荐系统大会论文集. 第3–11页 (2019) 28. Ren, Y., Yang, Q., Wu, Y., Xu, W., Wang, Y., Zhang, Z.: 用于重排序推荐的非自回归生成模型. 载于：第30届ACM SIGKDD知识发现与数据挖掘大会论文集. 第5625–5634页 (2024) 29. Shen, T., Wang, H., Wu, C., Chin, J.Y., Guo, W., Liu, Y., Guo, H., Lian, D., Tang, R., Chen, E.: P-law: 在大型推荐模型中利用熵引导预测定量缩放定律. 载于：第三十九届神经信息处理系统年度会议 30. Shi, X., Yang, F., Wang, Z., Wu, X., Guan, M., Liao, G., Yongkang, W., Wang, X., Wang, D.: PIER: 电子商务中基于排列级兴趣的端到端重排序框架. 载于：第29届ACM SIGKDD知识发现与数据挖掘大会论文集. 第4823–4831页 (2023) 31. Stern, M., Shazeer, N., Uszkoreit, J.: 面向深度自回归模型的分块并行解码. 神经信息处理系统进展 **31** (2018) 32. Wang, C., Zhang, J., Chen, H.: 半自回归神经机器翻译. arXiv预印本 arXiv:1808.08583 (2018) 33. Wang, H., Guo, W., Zhang, L., Chin, J.Y., Ye, Y., Guo, H., Liu, Y., Lian, D., Tang, R., Chen, E.: 生成式大型推荐模型：推荐领域大语言模型的新兴趋势. 载于：2025年ACM万维网会议伴随论文集. 第49–52页 (2025) 34. Wang, H., Han, Y., Wang, K., Cheng, K., Wang, Z., Guo, W., Liu, Y., Lian, D., Chen, E.: 面向高效多行为序列推荐的去噪预训练与定制化提示学习. arXiv预印本 arXiv:2408.11372 (2024) 35. Wang, H., Lian, D., Tong, H., Liu, Q., Huang, Z., Chen, E.: Hypersorec: 利用多方面双曲用户和物品表示进行社交感知推荐. ACM信息系统汇刊 (TOIS)**40**(2), 1–28 (2021) 36. Wang, H., Xu, T., Liu, Q., Lian, D., Chen, E., Du, D., Wu, H., Su, W.: Mcne: 学习社交网络多重条件网络表示的端到端框架. 载于：第25届ACM SIGKDD知识发现与数据挖掘国际大会论文集. 第1064–1072页 (2019) 37. Wang, H., Yin, M., Zhang, L., Zhao, S., Chen, E.: Mf-gslae: 面向双目标跨域推荐的多因素用户表示预训练框架. ACM信息系统汇刊 **43**(2), 1–28 (2025) 38. Wang, J., Yin, M., Wang, H., Chen, E.: 利用去相关专家网络增强点击率预测. arXiv预印本 arXiv:2505.17925 (2025)

39. Wang, K., Wang, H., Guo, W., Liu, Y., Lin, J., Lian, D., Chen, E.: Dlf: 通过动态低阶感知融合增强显式-隐式交互以进行点击率预测. 载于：第48届国际 ACM SIGIR 信息检索研究与发展大会论文集. 第2213–2223页 (2025) 40. Wang, K., Wang, H., Song, K., Guo, W., Cheng, K., Li, Z., Liu, Y., Lian, D., Chen, E.: 点击率预测中压缩嵌入的通用框架. 载于：高级应用数据库系统国际会议. 第84–100页. Springer (2025) 41. Wang, S., Wei, X., Kou, S., Wang, C., Chen, W., Tang, Q., Zhu, Y., Xiao, X., Wang, X.: Nlgr: 在个性化推荐系统中利用邻居列表进行生成式重排序. 载于：2025年ACM万维网会议伴随论文集. 第530–537页 (2025) 42. Weng, M., Xi, Y., Liu, W., Chen, B., Lin, J., Tang, R., Zhang, W., Yu, Y.: 超越正向历史：基于列表级混合反馈的重排序. arXiv预印本 arXiv:2410.20778 (2024) 43. Wu, L., Zheng, Z., Qiu, Z., Wang, H., Gu, H., Shen, T., Qin, C., Zhu, C., Zhu, H., Liu, Q., 等: 面向推荐的大语言模型综述. 万维网 **27**(5), 60 (2024) 44. Xi, Y., Liu, W., Dai, X., Tang, R., Zhang, W., Liu, Q., He, X., Yu, Y.: 面向推荐的效用最大化上下文感知重排序. arXiv预印本 arXiv:2110.09059 (2021) 45. Xi, Y., Liu, W., Zhu, J., Zhao, X., Dai, X., Tang, R., Zhang, W., Zhang, R., Yu, Y.: 结合用户行为历史的多层次交互重排序. 载于：第45届国际 ACM SIGIR 信息检索研究与发展大会论文集. 第1336–1346页 (2022) 46. Xia, H., Ge, T., Wang, P., Chen, S.Q., Wei, F., Sui, Z.: 推测解码：利用推测执行加速序列到序列生成. arXiv预印本 arXiv:2203.16487 (2022) 47. Xie, W., Wang, H., Fang, M., Yu, R., Guo, W., Liu, Y., Lian, D., Chen, E.: 打破瓶颈：面向序列推荐的用户专属优化与实时推理集成. 载于：第31届ACM SIGKDD知识发现与数据挖掘大会论文集 第2卷. 第3333–3343页 (2025) 48. Xie, W., Wang, H., Zhang, L., Zhou, R., Lian, D., Chen, E.: 打破确定性：使用离散状态空间扩散模型对序列推荐进行模糊建模. 神经信息处理系统进展 **37**, 22720–22744 (2024) 49. Xu, X., Wang, H., Guo, W., Zhang, L., Yang, W., Yu, R., Liu, Y., Lian, D., Chen, E.: 面向点击率预测中长期用户行为建模的多粒度兴趣检索与精炼网络. 载于：第31届ACM SIGKDD知识发现与数据挖掘大会论文集 第1卷. 第2745–2755页 (2025) 50. Ye, Y., Guo, W., Chin, J.Y., Wang, H., Zhu, H., Lin, X., Ye, Y., Liu, Y., Tang, R., Lian, D., 等: Fuxi-α: 利用特征交互增强型 Transformer 扩展推荐模型. 载于：2025年ACM万维网会议伴随论文集. 第557–566页 (2025) 51. Ye, Y., Guo, W., Wang, H., Zhu, H., Ye, Y., Liu, Y., Guo, H., Tang, R., Lian, D., Chen, E.: Fuxi-\beta: 迈向轻量且快速的大规模生成式推荐模型. arXiv预印本 arXiv:2508.10615 (2025) 52. Yin, M., Pan, J., Wang, H., Wang, X., Zhang, S., Jiang, J., Lian, D., Chen, E.: 从特征交互到特征生成：点击率预测模型的生成式范式. arXiv预印本 arXiv:2512.14041 (2025)

53. Yin, M., Wang, H., Guo, W., Liu, Y., Zhang, S., Zhao, S., Lian, D., Chen, E.：序列推荐的数据集再生成。载于：第 30 届 ACM SIGKDD知识发现与数据挖掘大会论文集。第 3954–3965 页（2024） 54. Yu, H., Wu, Y., Wang, H., Guo, W., Liu, Y., Li, Y., Ye, Y., Du, J., Chen, E.：思维增强规划：大语言模型驱动的交互式推荐智能体。arXiv 预印本 arXiv:2506.23485（2025） 55. Zhang, J., Yin, M., Wang, H., Li, Y., Ye, Y., Lou, X., Du, J., Chen, E.：TD3：一种基于 Tucker分解的数据集蒸馏方法，用于序列推荐。载于：2025 年 ACM 万维网会议论文集。第 3994–4003 页（2025） 56. Zhang, L., Huang, Y., Lv, H., Yin, M., Li, L., Chen, Z., Wang, H., Chen, E.：为什么思考会造成伤害？诊断并纠正基础推荐模型中的推理偏移。arXiv 预印本 arXiv:2602.16587（2026） 57. Zhang, L., Lv, H., Pan, Q., Wang, K., Huang, Y., Miao, X., Xu, Y., Guo, W., Liu, Y., Wang, H., 等：下一个范式是以用户为中心的智能体，而非以平台为中心的服务。arXiv 预印本 arXiv:2602.15682（2026） 58. Zhang, L., Song, K., Lee, Y.Q., Guo, W., Wang, H., Li, Y., Guo, H., Liu, Y., Lian, D., Chen, E.：一举两得：利用单一生成式推荐模型统一召回与排序。载于：第 48 届国际 ACM SIGIR 信息检索研究与发展大会论文集。第 2224–2234 页（2025） 59. Zhang, L., Wang, H., Liu, Z., Yin, M., Huang, Y., Li, J., Guo, W., Liu, Y., Guo, H., Lian, D., 等：推荐系统能够自我教学吗？一种具有保真度控制的递归式自改进框架。arXiv 预印本 arXiv:2602.15659（2026） 60. Zhang, L., Wang, H., Zhang, S., Yin, M., Han, Y., Zhang, J., Lian, D., Chen, E.：跨域推荐中的自适应表示增强与逆向学习统一框架。载于：高级应用数据库系统国际会议。第 115–130 页。Springer（2024） 61. Zhang, R., Huang, Y., Lu, C., Wang, Q., Gao, Y., Wu, Y., Hu, Y., Xu, Y., Wang, W., Wang, H., 等：RAG-IGBench：面向开放域问答中基于 RAG 的交错生成的创新性评测。arXiv 预印本 arXiv:2512.05119（2025） 62. Zhou, R., Jia, Q., Chen, B., Xu, P., Sun, Y., Lou, S., Fu, C., Fu, M., Shen, G., Zhou, Z., 等：用户终身行为建模综述：效率与有效性视角（2026） 63. Zhou, R., Wang, H., Guo, W., Jia, Q., Xie, W., Xu, X., Liu, Y., Lian, D., Chen, E.：MIT：一种基于层次化任务关系建模的多塔信息传递框架。载于：2025 年 ACM 万维网会议伴随论文集。第 651–660 页（2025） 64. Zhuang, T., Ou, W., Wang, Z.：电子商务搜索中的全局优化互相影响感知排序。arXiv 预印本 arXiv:1805.08524（2018）