arXiv:2601.01448v1 [cs.IR] 4 Jan 2026

基于自适应扩散的推荐增强

Na Li[1], Fanghui Sun[1], Yan Zou[1],Yangfu Zhu[2],Xiatian Zhu[3],Ying Ma[1*]

[1]哈尔滨工业大学，黑龙江，中国 [2]首都师范大学，北京，中国[3]萨里大学，吉尔福德，英国{24s003043, 23b903066}@stu.hit.edu.cn, {Sunfanghui,y.ma}@hit.edu.cn, zhuyangfu@cnu.edu.cn, eddy.zhuxt@gmail.com

摘要

推荐系统通常依赖隐式反馈，在这种情况下只能观测到正向的用户-物品交互。因此，负采样对于提供恰当的负向训练信号至关重要。然而，现有方法往往会将可能为正样本但未被观测到的物品误标为负样本，而且无法精确控制负样本选择。我们旨在通过生成可控的负样本，而非从现有物品池中采样，来解决这些问题。为此，我们提出**基于扩散的增强推荐（ADAR）**，这是一种新颖且与模型无关的模块，利用扩散合成信息量丰富的负样本。受扩散中的渐进式扰动过程启发，ADAR 模拟从正样本到负样本的连续转变，从而能够细粒度地控制样本难度。为挖掘合适的负样本，我们从理论上确定正样本转变为负样本的转变点，并推导出一个分数感知函数，以自适应地确定最优采样时间步。通过识别这一转变点，ADAR 能够生成具有挑战性的负样本，有效地细化模型的决策边界。实验结果证实，ADAR 具有广泛的兼容性，能够显著提升现有推荐模型的性能，包括协同过滤和序列推荐，且无需修改模型架构。

1 引言

在现代推荐系统中，隐式反馈（Ding 等，2020）已成为学习用户偏好的主要信号，因为它在现实世界应用中无处不在。这类反馈通常包括点击、浏览或购买等用户行为，并将其视为正样本。然而，通常缺少明确的负信号，因此很难识别用户真正不喜欢的物品。但学习过程在很大程度上取决于能否区分用户偏好的物品与非偏好物品。在此背景下，构造高质量的负样本对于指导推荐模型至关重要（Rendle 和 Freudenthaler，2014）。

为了从隐式反馈中构造负样本，大多数现有模型采用采样方法，从未观测的用户-物品交互中选取负样本。一种常见方法是对这些未观测交互进行静态随机采样，因为这种方法简单且高效（Rendle 等，2012）。然而，这种方法无法提供足够的负向信号，限制了模型学习准确用户偏好的能力。为此，近期协同过滤研究探索了困难负采样策略（Zhang 等，2013），利用被错误地排在较高位置的未观测项目，从而提供更具挑战性的监督信号。在此基础上，研究者提出了更复杂的采样策略，例如 MixGCF（Huang 等，2021）和 AHNS（Lai 等，2024），通过混合或评分来寻找困难负样本。在序列推荐中，用户行为的时间和上下文动态进一步加大了采样难度。GNNO（Fan 等，2023）通过根据全局转移识别困难样本来改进采样，而近期的上下文感知方法（Seol 和 Choi，2025）则会根据随时间变化的分布调整采样。

然而，这些策略并非最优，且存在若干局限。首先，它们往往会引入虚假的负信号，因为某些未观测物品实际上可能符合用户兴趣，只是由于曝光有限而未被用户看到。将可能相关的物品错误地视为负样本，可能会在训练过程中引入误导性信号，从而阻碍用户偏好的学习。其次，现有方法无法在负采样过程中进行细粒度控制。尽管动态策略（Zhang 等，2013；Zhao 等，2023）通过根据候选物品的得分对其排序，改进了静态启发式方法，但它们缺乏灵活性，无法获得难度可控的负样本。具体而言，现有方法无法精确调节正样本与负样本之间的实际差距，导致排序性能不佳。

我们不再依赖从现有物品池中抽取的负样本，而是旨在对从正样本到负样本的连续转变进行建模，以解决这些局限。为此，我们采用一种基于扩散过程的生成式方法，该方法能够自然地模拟这一渐进式转变。扩散模型（Ho、Jain 和 Abbeel 2020；Dhariwal 和 Nichol 2021a）最初是为高保真图像合成而设计的（Zhou 等，2025），通过逐步将结构化输入转化为噪声，并学习对这一过程进行逆向还原。我们观察到，在前向加噪过程中，正样本会逐渐失去其信息

*通讯作者。版权所有 © 2026，人工智能促进协会（www.aaai.org）。保留所有权利。

性特征，最终变得与负样本无法区分。这种连续退化为识别转变点提供了一个自然视角，即样本从正样本跨越为负样本的时刻。

本文提出了**自**适应**扩**散式**增**强**推**荐方法（**ADAR**），这是一种新颖且与模型无关的增强模块，利用扩散来自适应地合成具有信息量的负样本。我们的核心思想是通过扩散过程对正样本的退化进行建模。在这一过程中，正样本会逐渐受到扰动，并在其身份从正样本转变为负样本时发生关键转变。因此，我们可以将每个时间步的输出视为候选负样本池。随后，我们对这一转变进行理论刻画，并引入一种分数感知函数来自适应地确定最佳采样时间步。借助这一明确定义的转变点，ADAR 能够自适应地生成具有信息量且富有挑战性的负样本。这些生成样本随后可作为即插即用增强，用于提升各类现有推荐模型。

我们的主要贡献总结如下：

- 我们提出了 ADAR，这是一种新颖且与模型无关的增强模块，利用扩散生成高质量负样本，从而解决现有方法中假负信号和可控性方面的局限。
- 我们从理论上定义了扩散过程中的一个转变点，用于标记正样本何时变为负样本，从而能够自适应地选择信息丰富的负样本。
- ADAR 兼容多种模型，包括协同过滤和序列推荐，展现出强大的泛化能力，且无需进行任何特定于模型的修改。

2 相关工作

2.1 负采样

在推荐中，负采样在构建训练对方面发挥着至关重要的作用，引导模型区分偏好物品和非偏好物品。学习效果在很大程度上取决于这些负样本的质量和难度。在未观测交互上进行简单的均匀采样（Rendle 等，2012）通常会产生简单的负样本和较弱的监督信号。为获得更具判别性的用户/物品表示，困难负采样会选择模型排名较高的具有挑战性的负样本（Zhang 等，2013）。MixGCF（Huang 等，2021）和 DropMix（Ma、Chen 和 Li，2023）通过维度混合机制获得负样本。更进一步，DINS（Wu 等，2023）和 TriSampler（Yang 等，2024）将采样区域扩展到空间区域和三角区域。AHNS（Lai 等，2024）能够选择难度不同的现有负样本。

在序列推荐中，负采样必须处理时间和上下文动态。GNNO（Fan 等，2023）基于全局物品转移挖掘困难负样本，而上下文感知方法（Seol 和 Choi，2025）则进行适应性采样，以适应依赖上下文的物品分布，从而在动态用户行为下提升推荐质量。

然而，这些方法缺乏一种有原则的方法来建模正样本与负样本之间的连续转换，导致模型性能欠佳。

2.2 扩散模型

扩散模型（Ho、Jain 和 Abbeel 2020；Dhariwal 和 Nichol 2021b；Ho 等 2022）是一种生成建模方法，通过逐步向数据添加噪声并学习逆转这一过程，能够有效捕捉数据分布，适用于图像（Yi 等 2024）、文本（Arriola 等 2025）或分子生成（Wang 等 2024）等任务。在推荐领域，扩散模型通常用于建模用户偏好。例如，DiffuRec（Li、Sun 和 Li 2023）采用去噪扩散，结合物品信息对序列推荐进行建模。DiQDiff（Mao 等 2025）通过语义码本引导扩散模型。CCDRec（Yang 等 2025）提出一种结合课程学习的条件扩散，用于多模态推荐。此外，扩散模型在负采样方面的潜力也受到了不同领域的关注。DMNS（Nguyen 和 Fang 2024）通过条件扩散为链接预测制定多级采样方案，而 MMKGC（Niu 和 Zhang 2025）则通过融入多模态语义，将这一方法扩展到知识图谱。

然而，现有的基于扩散的采样器通常依赖固定时间步，且往往针对特定领域进行设计。相比之下，我们的方法引入了转折点驱动采样，能够自适应地选择负样本，并作为即插即用模块来增强模型。

3 预备知识

3.1 问题定义

我们将历史用户—物品交互集合记为$\mathcal{D}^+ = \{(u,\ i) | u \in \mathcal{U},\ i \in \mathcal{I}\}$，其中 $\mathcal{U}$和 $\mathcal{I}$分别表示用户集合和项目集合。我们将所有未观测交互 $\mathcal{D}^- = \{(u,\ j) | u \in \mathcal{U},\ j \notin \mathcal{D}_u^+\}$均视为负样本候选。标准推荐模型通过在三元组$(u,\ i,\ j)$上训练来优化成对损失，其中 i 是正物品，j是从 $\mathcal{D}^-$中采样得到的负物品。我们的目标是通过对正样本 i进行基于扩散的扰动，生成额外的负样本，从而提升模型性能。这些样本可以模拟困难负样本，进而促使模型学习更具判别性的表示。

3.2 扩散模型

扩散模型（Ho、Jain 和 Abbeel 2020年；Dhariwal 和 Nichol 2021a）通过前向过程向输入添加高斯噪声，然后以迭代方式执行反向过程，对输入进行去噪并重建原始输入。给定输入 $\mathbf{x}_0 \sim q(\mathbf{x}_0)$ 和扩散步总数 T，以获得后续状态 $\mathbf{x}_1, \mathbf{x}_2, ..., \mathbf{x}_T$，扩散模型的前向过程可定义为

$$q(\mathbf{x}_t|\mathbf{x}_0) = \mathcal{N}(\mathbf{x}_t; \sqrt{\bar{\alpha}_t}\mathbf{x}_0, (1-\bar{\alpha}_t)\mathbf{I}), \tag{1}$$

$$\mathbf{x}_t = \sqrt{\bar{\alpha}_t}\mathbf{x}_0 + \sqrt{(1-\bar{\alpha}_t)}\epsilon_t, \tag{2}$$

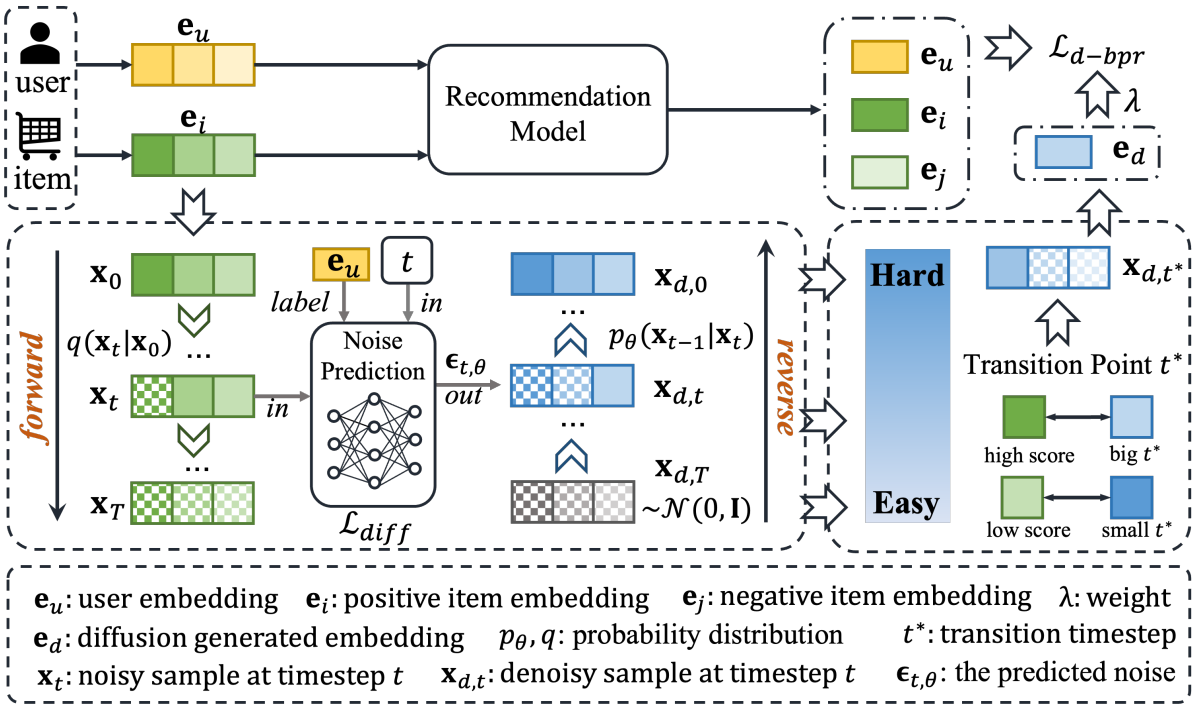

图 1：所提出的 ADAR 概览：ADAR 利用扩散模型的生成动态，生成难度可控且具有意义的负样本。首先，我们应用扩散模型，通过逐步破坏正样本来生成负候选样本。然后，我们通过评分感知函数确定转变点 t^*，从而自适应地选择增强负样本。ADAR 可以作为即插即用模块，增强多种推荐模型。

其中，累积信号保留率 $\bar{\alpha}_t = \prod_{s=1}^{t} \alpha_s$, $\alpha_t = 1-\beta_t$，且 $\beta_1, \beta_2, ..., \beta_T$ 控制所添加噪声的量。$t \in [0, T]$ 表示时间步的索引。ϵ_t 表示从 $\mathcal{N}(0, \mathbf{I})$ 中采样的噪声。通常，β_t 会随时间按照预定义调度（例如线性、余弦或 sigmoid）单调递增，从而使噪声水平逐渐升高。

反向过程使用一个参数为 θ 的神经网络，来预测前向过程中添加的噪声。反向变换可以表示为：

$$p_\theta(\mathbf{x}_{t-1}|\mathbf{x}_t) = \mathcal{N}(\mathbf{x}_{t-1}; \mu_\theta(\mathbf{x}_t, t), \sum_\theta(\mathbf{x}_t, t)). \quad (3)$$

为了对 $p_\theta(\mathbf{x}_{t-1}|\mathbf{x}_t)$ 进行建模，去噪扩散概率模型（Ho、Jain 和 Abbeel 2020）通常预先固定 $\sum_\theta(\mathbf{x}_t, t)$，并使用重参数化技巧推导出 $\mu_\theta(\mathbf{x}_t, t)$：

$$\mu_\theta(\mathbf{x}_t, t) = \frac{1}{\sqrt{\alpha_t}}\mathbf{x}_t - \frac{1-\alpha_t}{\sqrt{\alpha_t}\sqrt{1-\bar{\alpha}_t}}\epsilon_\theta(\mathbf{x}_t, t), \quad (4)$$

其中，$\epsilon_\theta(\mathbf{x}_t, t)$ 是预测目标，应与高斯噪声相似。在实际操作中，我们从 $\mathbf{x}_T \sim \mathcal{N}(0, \mathbf{I})$ 开始，然后逐步恢复 $\mathbf{x}_0$。

4 方法

我们提出了用于推荐的自适应扩散增强（ADAR），这是一个与模型无关的模块，用于生成高质量的负样本。ADAR 通过扩散过程模拟正样本的逐步退化，并详细阐述了该过程的构式。ADAR 的主要架构如图 1 所示。

4.1 基于扩散的样本生成

本节将介绍 ADAR 如何生成候选负样本。ADAR 学习渐进式加噪和去噪过程，从而能够为推荐生成可控的负样本。

令 i in $(u, i) \in \mathcal{D}^+$ 为一个正样本。首先从编码器 $\phi(i)$中获取其对应的嵌入 $\mathbf{e}_i \in \mathbb{R}^d$，该编码器可根据具体的推荐任务由任意不同模型构建。用户表示 $\mathbf{e}_u$ 同样由 $\phi(u)$ 获取。

前向过程。我们根据公式 2 应用前向扩散过程，生成一系列噪声逐步增加的嵌入。具体而言，我们将 $\mathbf{x}_0$ 设为$\mathbf{e}_i$，执行前向扩散过程，并得到带噪样本集 $\mathcal{X} = \{\mathbf{x}_t\}_{t=0}^{T}$。此过程逐渐去除原始交互中的正样本信息，使$\mathbf{x}_t$ 趋近于标准高斯分布。

噪声预测模型。为了生成候选负样本，我们需要估计每个时间步添加的噪声，可将其表示为

$$\epsilon_{t,\theta} = \tau(\mathbf{x}_t, \mathbf{e}_t, \mathbf{e}_u; \theta), \quad (5)$$

其中，$\mathbf{e}_t = \mathrm{PE}(t)$ 是时间嵌入，τ 是噪声预测模型，其可学习参数为 θ。同时，为了充分利用用户嵌入$\mathbf{e}_u$，我们采用条件扩散模型（Dhariwal and Nichol 2021b；Ho et al. 2022），将用户嵌入作为标签信息输入，以引导生成过程。

我们遵循（Ho、Jain 和 Abbeel 2020）中的方法，采用正弦余弦编码构造连续、周期性的时间嵌入。时间步嵌入的公式为：

$$\mathrm{PE}(t) = \begin{cases} sin(t \cdot 10000^{-\frac{2i}{d_t}}), \text{if } i \text{ is even} \\ cos(t \cdot 10000^{-\frac{2i}{d_t}}), \text{if } i \text{ is old} \end{cases}, \quad (6)$$

其中，$i \in [0, d-1]$ 是维度索引。该编码方法有助于模型学习相对时间步关系。

为了更好地适应推荐任务，我们使用特征级线性调制（FiLM）（Perez 等 2018）实现τ，根据时间步和标签嵌入动态调制中间特征表示。该方法能够高效地进行噪声预测，同时确保对结构化推荐数据进行轻量级适配。具体而言，τ 定义为：

$$\epsilon_{t,\theta} = \gamma(\mathbf{e}_t, \mathbf{e}_u; \theta_\gamma) \odot \mathbf{x}_t + \eta(\mathbf{e}_t, \mathbf{e}_u; \theta_\eta), \quad (7)$$

其中，γ 和 η 分别表示缩放和偏移，$\odot$ 表示逐元素乘法。在我们的模型中，这些组件通过一个包含多个全连接层的简单多层感知机实现。

扩散损失。遵循扩散模型的标准公式（Dhariwal 和 Nichol 2021a），我们采用均方误差（MSE）损失，以最小化反向过程中的预测噪声与前向扩散期间注入的高斯噪声之间的差异。然而，在推荐场景中，仅恢复噪声并不能确保最终生成样本保留原始正样本实例的语义本质（Li、Sun 和 Li 2023）。为此，我们引入额外的损失，以强制最终生成输出与其对应的正样本之间保持一致。具体而言，对于给定的时间步 t，扩散损失函数定义为：

$$\mathcal{L}_{diff} = \|\epsilon - \epsilon_{t,\theta}\|^2 + ||\mathbf{x}_0 - \mathbf{x}_{d,0}||^2. \quad (8)$$

反向过程。噪声预测模型 τ 训练完成后，我们使用它通过反向扩散过程生成候选样本，其中每个时间步的输出都可作为潜在的负样本。具体而言，我们从标准正态分布中采样一个高斯噪声，作为潜在空间中受扰动程度最大的版本：

$$\mathbf{x}_{d,T} \sim \mathcal{N}(0, \mathbf{I}), \quad (9)$$

并逐步应用反向更新规则：

$$\mathbf{x}_{d,t-1} = \frac{1}{\sqrt{\alpha_t}}\mathbf{x}_{d,t} - \frac{1-\alpha_t}{\sqrt{\alpha_t}\sqrt{1-\bar{\alpha}_t}}\epsilon_{t,\theta}, \quad (10)$$

对于 $t = T,\ T-1,\ \ldots\ldots,\ 1$。每个去噪步骤都会逐步恢复信息，从而得到去噪样本集$\mathcal{X}_d = \{\mathbf{x}_{d,\ t}\}_{t=0}^{T}$。这些输出是新颖且合理的候选样本，类似于正物品受扰动后的版本。

4.2 过渡点检测

然而，$\mathcal{X}_d$ 并非所有生成样本都同样有助于训练。与原始正样本过于相似的样本可能会加剧冗余，而那些噪声过多的样本则可能引入有害信号。为此，我们提出一种自适应机制来识别转变点，即生成样本在用户偏好方面从正样本转变为负样本的时刻。我们选取转变点处的生成样本作为增强负样本。该样本接近决策边界，因此能为训练提供最大的效用。

定理 1。设 μ^+ 为正物品得分。那么，过渡点t^* 处的累积信号保留 $\bar{\alpha}_{t^*}$ 值与 μ^+负相关。

证明。我们首先将用户偏好分数建模为函数 $f(\mathbf{u},\ \mathbf{x})$，其中$\mathbf{u}$和$\mathbf{x}$ 分别表示用户和物品的表征（其中$\mathbf{u} = \mathbf{e}_u$）。如前所述，$\mathbf{x}_0$ 表示一个正样本，而$\mathbf{x}_t$ 表示其在扩散步 t时加噪后的版本。假设评分函数 $f(\mathbf{u},\ \mathbf{x})$关于$\mathbf{x}$ 近似线性（例如内积模型），则加噪物品$\mathbf{x}_t$ 的期望偏好分数为：

$$\begin{aligned} \mathbb{E}[f(\mathbf{u}, \mathbf{x}_t)] &= \mathbb{E}[f(\mathbf{u}, \sqrt{\bar{\alpha}_t}\mathbf{x}_0 + \sqrt{(1-\bar{\alpha}_t)}\epsilon_t)] \\ &= \sqrt{\bar{\alpha}_t} \cdot f(\mathbf{u}, \mathbf{x}_0) \\ &= \sqrt{\bar{\alpha}_t} \cdot \mu^+, \end{aligned}$$

其中，$\mu^+ = f(\mathbf{u},\ \mathbf{x}_0)$ 是原始正物品的分数，假设其大于零，以反映用户偏好。我们将转变点 t^* 定义为：用户对$\mathbf{x}_t$ 的期望分数低于预定义负阈值 μ^-时所对应的第一个扩散步。即，

$$\mathbb{E}[f(\mathbf{u}, \mathbf{x}_{t^*})] = \mu^- \quad \Rightarrow \bar{\alpha}_{t^*} = \left(\frac{\mu^-}{\mu^+}\right)^2.$$

对 μ^+ 求导：

$$\frac{d\bar{\alpha}_{t^*}}{d\mu^+} = -2\left(\frac{\mu^-}{\mu^+}\right)^2 \cdot \frac{1}{\mu^+} < 0,$$

这表明 $\bar{\alpha}_{t^*}$ 关于 μ^+ 严格递减。 □

由于 $\bar{\alpha}_t$ 的值是关于 t 的严格递减函数，因此可知，t^* 必须随 μ^+ 增大。也就是说，分数较高的正样本在扩散过程中能更久地保留其信息身份，并在更晚的步骤发生转变。

尽管这一公式提供了理论指导，但实际数据集缺乏明确的负交互，因此无法观测到 μ^-。为解决这一问题，我们采用一种基于观测正分数$p_s = f(\mathbf{u},\ \mathbf{x}_0)$ 的参数化启发式方法来近似 t^*。具体而言，我们定义一个分数感知函数：

$$t^* = \mathrm{sigmoid}(\omega \cdot \exp(k \cdot p_s)) \cdot T, \quad (11)$$

其中，$w > 0$ 和 $k > 0$ 是可调节的超参数，用于控制转变函数的形状和尺度。实践中，我们可以设定 $\omega = 1$ 和 $k = 1$；大量实验表明，这些设置在大多数数据集上都能稳定提升性能。

这一分数感知函数与我们的理论结果一致，捕捉了正样本分数与累积信号保留率 $\bar{\alpha}_{t^*}$ 值之间的负相关关系。通过

将较高的 p_s 自适应地映射到更深的扩散步 t^*，它会根据观测到的正样本分数动态调整生成样本的距离。

确定转变点 t^* 后，我们从去噪样本集中选取时间步 t^* 的样本 $\mathbf{x}_{d,\ t^*}$，作为最终的增强负样本。

4.3 优化目标

为了优化推荐模型，我们采用贝叶斯个性化排序（BPR）（Rendle 等，2012），这是一种广泛应用于隐式反馈成对学习的目标函数。鉴于 ADAR 作为与模型无关的增强模块运行，因此可以无缝集成到现有推荐模型中，而无需修改其核心结构。

在我们的公式中，令 $\mathbf{e}_i$ 表示通过基线负采样方法选取的物品嵌入，令 $\mathbf{e}_d$ 表示通过 ADAR 生成的样本的嵌入。为了充分利用生成负样本所包含的信息，我们将其作为补充纳入学习目标。具体而言，总损失定义为

$$\mathcal{L}_{d-bpr} = -\sum_{u,i,j,d} \ln \sigma(\mathbf{e}_u^\top \mathbf{e}_i - (\mathbf{e}_u^\top \mathbf{e}_j + \lambda \mathbf{e}_u^\top \mathbf{e}_d)), \quad (12)$$

其中，加权因子 $\lambda \in [0,1]$ 是一个超参数，用于调节生成样本的贡献。ADAR 引入难度可控的负样本，从而促使模型构建更具判别性的表征。我们采用扩散模型与编码器之间的交替训练策略。为全面了解 ADAR 的训练流程，算法 1 给出了训练伪代码。

算法 1：ADAR 1：输入：隐式反馈集合 $\mathcal{D}^+ = \{(u,i) | u \in \mathcal{U}, i \in \mathcal{I}\}$，预定义超参数 T 和 λ。2：输出：编码器模型、扩散模型。3：初始化 4：当未收敛时执行 5：对于从 $\mathcal{D}^+$ 采样的每个小批量 $\mathcal{B}$，执行 6：获取用户 u 和正物品 i 的嵌入 7：// 基于扩散的样本生成 8：$\mathbf{x}_t = \sqrt{\bar{\alpha}_t}\mathbf{x}_0 + \sqrt{(1-\bar{\alpha}_t)}\epsilon_t, \epsilon_t \sim \mathcal{N}(0, \mathbf{I})$ 9：$\mathbf{e}_t = \mathbf{PE}(t)$ 10：通过最小化 $\mathcal{L}_{diff}$ 优化扩散模型 11：按照 $\mathbf{x}_{d,t-1} = \frac{1}{\sqrt{\alpha_t}}\mathbf{x}_{d,t} - \frac{1-\alpha_t}{\sqrt{\alpha_t}\sqrt{1-\bar{\alpha}_t}}\overline{\epsilon_{t,\theta}}$ 迭代计算反向扩散步 12：获得候选样本集 $\mathcal{X}_d = \{\mathbf{x}_{t=0}^T\}$ 13：// 转折点检测 14：$t^* = \mathbf{sigmoid}(\omega \cdot \mathbf{exp}(k \cdot p_s)) \cdot T$ 15：获得转变点 $\mathbf{x}_{d,t^*}$ 的嵌入 16：$\mathbf{e}_d = \mathbf{x}_{d,t^*}$ 17：~~// 训练编码器模型~~ 18：使用现有方法获取三元组（u, i, j） 19：通过最小化 $\mathcal{L}_{d-bpr}$ 优化编码器 20：结束循环 21：结束循环

数据集	#用户	#项目	#交互行为	Avg. 长度	密度
Beauty	22,363	12,101	0.2m	8.9	0.05%
Toys	19,412	11,924	0.17m	8.6	0.07%
Sport	35,598	18,357	0.3m	8.3	0.05%
Yelp	30,431	20,033	0.3m	8.3	0.05%

表1：数据集统计信息。

5 实验

5.1 实验设置

数据集。 我们在四个基准数据集上开展实验：Beauty、Toys、Sport 和 Yelp，这些数据集常用于协同过滤（CF）和序列推荐（SR）任务。所有数据集均源自亚马逊评论数据集和 Yelp评论数据集。四个数据集的详细统计信息汇总于表1。对于协同过滤任务，我们遵循标准预处理流程（Lai 等，2024），将用户行为日志转换为用户-物品交互矩阵。每位用户的交互记录随机划分为 80% 用于训练，20% 用于测试。对于序列推荐任务，首先按时间顺序将用户交互记录整理为序列，并过滤掉交互次数少于五次的用户，以确保建模稳定性。

评估指标。 为评估推荐效果，我们采用两种广泛使用的排序指标：Recall@10、20 和 NDCG@10、20。Recall 衡量在前 k 项推荐中成功检索到的相关项目比例，而 NDCG 则考虑命中项目的位置，对列表中排名更靠前的正确项目赋予更高权重。

集成方法。 为评估所提出的 ADAR 的有效性，我们在两种主要的推荐范式下开展实验：协同过滤（CF）和序列推荐（SR）。

对于协同过滤，我们采用以下模型：NGCF（Wang等人（2019））、LightGCN（He等人（2020））、MixGCF（Huang 等，2021）和 AHNS（Lai 等，2024）。对于序列推荐，我们考察三种代表性序列模型，并使用 DR4SR（Yin等人（2024））对数据集进行增强：GRU4Rec（Hidasi 等，2015）、SASRec（Kang和McAuley（2018））和 CL4SRec（Xie等人（2022））。更详细的基线方法介绍请参阅附录。

对于每个模型，我们都在不修改其核心架构的前提下融入 ADAR，以确保与原始基线方法进行公平、直接的比较。

实现细节。 嵌入维度固定为 64，嵌入参数采用 Xavier初始化（Glorot和Bengio（2010））进行初始化。我们使用 Adam优化器（Kingma和Ba（2014））优化所有参数，默认学习率为 0.001。对于协同过滤，我们使用默认小批量大小 2,048。对于序列推荐，我们使用默认小批量大小 256，最大序列长度 N 设为 50。对于 ADAR，我们固定 $\omega = 1$ 和 $k = 1$，并在范围 $[0,1]$ 内搜索 λ。对于协同过滤，最大扩散步数 T 设为 50；对于序列推荐，则设为 20。

Task	方法	亚马逊美妆			亚马逊玩具			亚马逊运动			Yelp		
		R@10	R@20	N@10	R@10	R@20	N@10	R@10	R@20	N@10	R@10	R@20	N@10
CF	NGCF	6.37	9.50	4.11	5.94	8.50	3.92	3.92	6.21	2.50	4.27	6.92	2.73
	+ADAR	**8.13**	**11.76**	**5.21**	**7.82**	**11.39**	**5.08**	**5.29**	**8.11**	**3.35**	**5.06**	**8.19**	**3.24**
	RelImp	27.6%	23.8%	26.8%	31.6%	34.0%	29.6%	34.9%	30.6%	34.0%	18.5%	18.3%	18.7%
	LightGCN	8.69	12.40	5.77	8.22	11.50	5.55	5.96	8.62	3.82	5.27	8.33	3.39
	+ADAR	**8.99**	**12.88**	**6.05**	**8.46**	**11.93**	**5.84**	**6.32**	**9.08**	**4.11**	**5.55**	**8.81**	**3.58**
	RelImp	3.45%	3.55%	4.85%	2.92%	3.74%	5.23%	6.04%	5.34%	7.59%	5.31%	5.76%	5.60%
	MixGCF	9.82	13.67	6.63	9.05	12.82	6.19	6.25	8.98	4.21	5.80	9.01	3.72
	+ADAR	**10.01**	**14.10**	**6.90**	**9.25**	**13.09**	**6.39**	**6.31**	**9.13**	**4.32**	**5.95**	**9.31**	**3.86**
	RelImp	1.93%	3.15%	4.07%	2.21%	2.11%	3.23%	0.96%	1.67%	2.61%	2.59%	3.33%	3.76%
	AHNS	9.66	13.50	6.51	8.89	12.55	6.06	6.69	9.70	4.39	5.53	8.88	3.60
	+ADAR	**10.05**	**14.04**	**6.89**	**9.15**	**12.91**	**6.21**	**6.84**	**9.85**	**4.52**	**5.82**	**9.19**	**3.80**
	RelImp	4.04%	4.00%	5.84%	2.92%	2.87%	2.48%	2.24%	1.55%	2.96%	5.24%	3.49%	5.56%
SR	GRU4Rec	2.79	4.87	1.37	2.24	3.71	1.08	1.81	3.17	0.90	2.30	3.88	1.14
	+ADAR	**4.34**	**6.96**	**2.17**	**3.78**	**5.84**	**1.89**	**2.55**	**4.09**	**1.39**	**3.21**	**5.17**	**1.59**
	RelImp	55.6%	42.9%	58.4%	68.8%	57.4%	73.4%	40.9%	29.0%	54.4%	39.6%	33.2%	39.5%
	SASRec	5.99	8.82	3.20	7.27	9.95	4.13	2.97	4.72	1.58	2.99	4.99	1.50
	+ADAR	**6.32**	**9.69**	**3.27**	**7.72**	**10.52**	**4.50**	**3.62**	**5.71**	**1.89**	**3.30**	**5.58**	**1.66**
	RelImp	5.51%	9.87%	2.19%	6.19%	5.73%	8.96%	21.9%	21.0%	19.6%	10.4%	11.8%	10.7%
	CL4SRec	7.24	10.26	4.20	7.80	10.59	4.54	4.33	6.19	2.37	3.27	5.58	1.60
	+ADAR	**7.44**	**10.65**	**4.31**	**8.12**	**11.13**	**4.73**	**4.46**	**6.35**	**2.50**	**3.69**	**5.86**	**1.82**
	RelImp	2.76%	3.80%	2.62%	4.10%	5.10%	4.19%	3.00%	2.58%	5.49%	12.8%	5.02%	13.8%

表 2：四个数据集上的性能。RelImp：相对提升。我们进行了配对 t 检验，以验证对于 $p < 0.05$，每个基线模型与我们提出的方法之间的差异在统计上是否显著。

5.2 结果分析

本节将各目标模型与我们的 ADAR 进行比较，以验证所提出模块的有效性。推荐的评估结果汇总于表 2（更多详情见附录），我们可以得出以下结论：

•**有效性**。ADAR 在多个数据集和基线模型上均能稳定提升性能。例如，经 ADAR 增强的 AHNS 在亚马逊美妆数据集上的 Recall@10 提升了 3.13%，NDCG@10 提升了 4.58%。其他方法也呈现出类似趋势，证实了 ADAR 在提升排序质量方面的有效性。

• **通用性**。ADAR 与多种模型架构均表现出良好的兼容性，包括协同过滤和序列推荐模型。ADAR 可与 GRU4Rec（基于循环神经网络）、SASRec（基于注意力机制）和 CL4SRec（基于对比学习）等模型兼容，在不修改底层模型架构的情况下提升性能。

• **互补性**。 除了具有普遍适用性外，ADAR 还能与现有的强大训练目标形成互补。例如，ADAR 将 Yelp 上 CL4SRec 的 NDCG@10 提高了 13.8%，这表明它引入了对比学习本身无法捕捉的额外有益训练信号。

方法	版本	R@10	R@20	N@10	N@20
NGCF	base	6.37	9.50	4.11	5.10
	随机	7.81	11.59	5.13	6.29
	固定	7.79	11.50	5.06	6.22
	混合	7.91	11.63	5.11	6.30
	ADAR	**8.13**	**11.76**	**5.21**	**6.34**
GRU4Rec	base	2.79	4.87	1.37	1.90
	随机	4.00	6.31	1.99	2.45
	固定	3.37	5.59	1.66	2.22
	混合	3.51	5.76	1.77	2.33
	ADAR	**4.34**	**6.96**	**2.17**	**2.82**

表3：亚马逊美妆上不同 t^* 选择策略的性能比较。

5.3 变体研究

在本节中，我们研究不同策略对选择 t^*的影响。回顾一下，t^* 表示最终增强负样本的扩散步，此时生成样本从正样本转变为负样本。我们比较了五种变体：(1) 基线，不进行增强；(2) 随机，随机采样 t^*；(3) 固定，将 t^* 固定在预定义的中点（我们将其设为 $T/2$）；(4) 混合，模型混合来自多个固定 t 的表征（例如 $T/2$、$T/4$、$T/8$和 $T/10$），其灵感来自 DMNS（Nguyen 和 Fang，2024）在链接预测中的方法；(5) ADAR，即本文提出的方法，它会自适应地确定 t^*，依据是

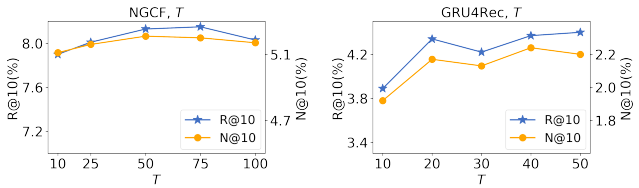

(a) NGCF， T (b) GRU4Rec， T

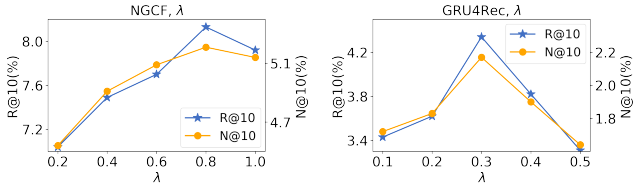

(c) NGCF， λ (d) GRU4Rec， λ

图 2：ADAR 在三种不同超参数下的性能比较。

理论准则。

实验在亚马逊美妆数据集上进行，评估了两个具有代表性的推荐模型：NGCF 和 GRU4Rec。我们在表3中报告结果，并得出以下观察：首先，ADAR 在两个模型上始终优于所有变体，这证实了自适应选择 t^* 能够生成比其他变体信息量更丰富的负样本。其次，混合变体虽然在链接预测中有效，但不太适用于推荐，其表现逊于 ADAR，甚至逊于随机变体。这表明，自适应且有理论依据的转变点对于选择高质量负样本至关重要。

5.4 超参数

为进一步研究 ADAR 的鲁棒性和稳定性，我们对扩散步 T和加权因子 λ进行了超参数分析。关于超参数 ω 和 k 的分析可参见附录。在本分析中，我们将其他超参数固定为默认值，以隔离每个单独变量的影响。实验在亚马逊美妆数据集上进行，采用两个具有代表性的骨干模型：用于协同过滤的 NGCF 和用于序列推荐的 GRU4Rec。如图 2(a) 和 2(b) 所示，随着T 增加，性能最初有所提升，但最终趋于饱和，这表明只需适量的扩散步即可捕捉语义转变。相比之下，图 2(c) 和 2(d) 表明，λ 呈现出明显的权衡特性，其中适中的取值始终能够带来更好的性能。这说明适度引入扩散信号能够有效指导负样本选择。

5.5 可视化

本节将深入分析可视化结果，以进一步考察 ADAR 在捕捉有意义的用户偏好方面的有效性。具体而言，我们从亚马逊美妆中随机抽取 2,000 名用户，并将其

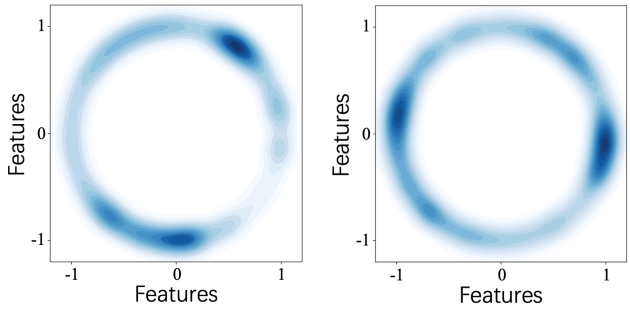

(a) NGCF (b) 使用 ADAR 的 NGCF

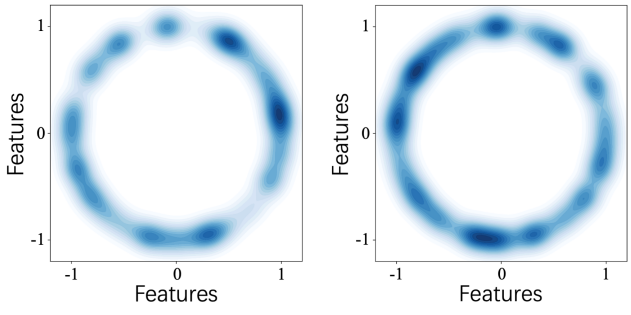

(c) SASRec (d) 使用 ADAR 的 SASRec

图 3：从 Amazon-beauty 数据集中学习到的用户表示分布。

学习到的用户嵌入投影到二维空间中。具体做法是将每个用户表示归一化到单位超球面上，并应用 t-SNE（Maaten 和 Hinton，2008）进行降维。如图 3 所示，基线模型（NGCF 和 SASRec）学习到的用户表示往往呈现出不均匀且聚集的模式。相比之下，经过 ADAR 增强的对应模型（NGCF with ADAR 和 SASRec with ADAR）生成的嵌入在整个空间中分布更加均匀。这表明，引入基于扩散的增强能够促使用户表示空间包含更丰富的信息并实现更好的解耦，从而有望提升泛化能力。

6 结论

为解决隐式反馈推荐中负信号不可靠、负采样控制有限这一难题，我们提出了基于扩散的增强模块 ADAR。ADAR 利用扩散模型的渐进式扰动过程生成高质量负样本。通过从理论上识别从正样本到负样本的转变点，ADAR 能够自适应地选择最优采样步数，从而获得信息丰富且具有挑战性的负样本。在多种骨干模型和推荐任务上开展的大量实验表明，ADAR 不仅有效，而且适用范围广，为提升推荐性能提供了稳健的解决方案。我们的代码已公开发布于 https://github.com/LN-Nlaine/ADAR。

致谢

本研究得到黑龙江省自然科学基金资助（No.LH2024F023）。

参考文献

Arriola, M.; Gokaslan, A.; Chiu, J. T.; Yang, Z.; Qi, Z.; Han, J.; Sahoo, S. S.; 和 Kuleshov, V. 2025。块扩散：在自回归模型与扩散语言模型之间进行插值。载于第十三届国际学习表征会议（*ICLR*）论文集。

Dhariwal, P.; 和 Nichol, A. 2021a。扩散模型在图像合成方面击败生成对抗网络。神经信息处理系统进展，34：8780–8794。

Dhariwal, P.; and Nichol, A. 2021b. 扩散模型在图像合成方面胜过生成对抗网络。神经信息处理系统进展, 34: 8780–8794. Ding, J.; Quan, Y.; Yao, Q.; Li, Y.; and Jin, D. 2020. 简化并增强隐式协同过滤的负采样鲁棒性。神经信息处理系统进展, 33: 1094–1105. Fan, L.; Pu, J.; Zhang, R.; and Wu, X.-M. 2023. 面向序列推荐的基于邻域的困难负样本挖掘。In第*46*届国际 *ACM SIGIR* 信息检索研究与发展会议论文集, 2042–2046. Glorot, X.; and Bengio, Y. 2010. 理解深度前馈神经网络训练的难点。In 第十三届人工智能与统计国际会议论文集, 249–256. JMLR Workshop and Conference Proceedings. He, X.; Deng, K.; Wang, X.; Li, Y.; Zhang, Y.; and Wang, M. 2020. LightGCN：简化并增强用于推荐的图卷积网络。In第*43*届国际 *ACM SIGIR* 信息检索研究与发展会议论文集 , 639–648. Hidasi, B.; Karatzoglou, A.; Baltrunas, L.; and Tikk, D. 2015. 基于会话的推荐与循环神经网络。*arXiv* 预印本 *arXiv:1511.06939*. Ho, J.; Jain, A.; and Abbeel, P. 2020. 去噪扩散概率模型。神经信息处理系统进展, 33: 6840–6851. Ho, J.; Saharia, C.; Chan, W.; Fleet, D. J.; Norouzi, M.; and Salimans, T. 2022. 用于高保真图像生成的级联扩散模型。机器学习研究期刊, 23(47): 1–33. Huang, T.; Dong, Y.; Ding, M.; Yang, Z.; Feng, W.; Wang, X.; and Tang, J. 2021. MixGCF：一种改进的图神经网络推荐系统训练方法。In 第*27*届 *ACM SIGKDD* 知识发现与数据挖掘会议论文集, 665–674. Kang, W.-C.; and McAuley, J. 2018. 自注意力序列推荐。In *2018*年 *IEEE* 国际数据挖掘会议（*ICDM*）, 197–206. IEEE. Kingma, D. P.; and Ba, J. 2014. Adam：一种随机优化方法。*arXiv* 预印本 *arXiv:1412.6980*。

Lai, R.; Chen, R.; Han, Q.; Zhang, C.; and Chen, L. 2024. 用于协同过滤的自适应难度负采样。In *AAAI*人工智能会议论文集, 第38卷, 8645–8652。

Li, Z.; Sun, A.; 和 Li, C. 2023。DiffuRec：用于序列推荐的扩散模型。*ACM* 信息系统学报，42(3)：1–28。

Ma, Y.; Chen, M.; 和 Li, X. 2023。DropMix：利用更难的负样本实现更优的图对比学习。载于*2023 IEEE* 国际数据挖掘会议研讨会（*ICDMW*），1105–1112。IEEE。

Maaten, L. v. d.; and Hinton, G. 2008. 使用 t-SNE 可视化数据。机器学习研究杂志，9(Nov): 2579–2605。

Mao, W.; Liu, S.; Liu, H.; Liu, H.; Li, X.; and Hu, L. 2025. 面向扩散序列推荐的卓越量化引导。载于*2025* 年 *ACM* 万维网会议论文集，425–435。

Nguyen, T.-K.; and Fang,Y. 2024. 用于链接预测的图上的基于扩散的负采样。载于*2024* 年 *ACM* 万维网会议论文集，948–958。

Niu, G.; and Zhang, X. 2025. 用于多模态知识图谱补全的基于扩散的层次负采样。*arXiv* 预印本 *arXiv:2501.15393*。

Perez, E.; Strub, F.; De Vries, H.; Dumoulin, V.; and Courville, A. 2018. FiLM：使用通用条件层进行视觉推理。载于*AAAI*人工智能会议论文集，第32卷。Rendle, S.; and Freudenthaler, C. 2014. 从隐式反馈改进物品推荐的成对学习。载于第*7*届 *ACM* 国际网络搜索与数据挖掘会议论文集，273–282。Rendle, S.; Freudenthaler, C.; Gantner, Z.; and Schmidt-Thieme, L. 2012. BPR：基于隐式反馈的贝叶斯个性化排序。*arXiv* 预印本 *arXiv:1205.2618*。Seol, J.; and Choi, J. 2025. 面向序列推荐的上下文感知负采样。*IEEE Access*。Wang, X.; He, X.; Wang, M.; Feng, F.; and Chua, T.-S. 2019. 神经图协同过滤。载于第*42*届国际 *ACM SIGIR* 信息检索研究与发展会议论文集，165–174。Wang, Y.; Liu, X.; Huang, F.; Xiong, Z.; and Zhang, W. 2024. 用于治疗性肽生成的多模态对比扩散模型。载于*AAAI*人工智能会议论文集，第38卷，3–11。Wu, X.; Yang, L.; Gong, J.; Zhou, C.; Lin, T.; Liu, X.; and Yu, P. S. 2023. 协同过滤中用于困难负样本的维度无关混合。载于第*32*届 *ACM* 国际信息与知识管理会议论文集，2785–2794。Xie, X.; Sun, F.; Liu, Z.; Wu, S.; Gao, J.; Zhang, J.; Ding, B.; and Cui, B. 2022. 面向序列推荐的对比学习。载于*2022 IEEE* 第*38*届国际数据工程会议（*ICDE*），1259–1273。IEEE。

Yang, Y.; Ma, H.; Meng, L.; Xu, S.; Xie, R.; and Meng, X. 2025. 面向多模态推荐的课程条件扩散。载于*AAAI*人工智能会议论文集，第39卷，13035–13043。Yang, Z.; Shao, Z.; Dong, Y.; and Tang, J. 2024. TriSampler：一种更优的密集检索负采样原则。载于*AAAI*人工智能会议论文集，第38卷，9269–9277。Yi, M.; Zhang, K.; Liu, P.; Zuo, T.; and Tian, J. 2024. DiffRAW：利用扩散模型从智能手机RAW图像生成具有可与数码单反相机媲美感知质量的 sRGB 图像。载于*AAAI*人工智能会议论文集，第38卷，6711–6719。Yin, M.; Wang, H.; Guo, W.; Liu, Y.; Zhang, S.; Zhao, S.; Lian, D.; and Chen, E. 2024. 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会议论文集，3954–3965。Zhang, W.; Chen, T.; Wang, J.; and Yu, Y. 2013. 通过动态负物品采样优化 Top-N 协同过滤。载于第*36*届国际 *ACM SIGIR* 信息检索研究与发展会议论文集，785–788。Zhao, Y.; Chen, R.; Lai, R.; Han, Q.; Song, H.; and Chen, L. 2023. 协同过滤的增强负采样。载于第*17*届*ACM*推荐系统会议论文集，256–266。Zhou, Y.; Gao, X.; Chen, Z.; and Huang, H. 2025. 注意力蒸馏：一种统一的视觉特征迁移方法。载于计算机视觉与模式识别会议论文集，18270–18280。