arXiv:2601.04291v1 [cs.IR] 7 Jan 2026

校正与加权：一种简单而有效的隐式反馈推荐损失

尹明磊、Chuanb o Hu、刘斌、龚振强、Yanfang(Fanny) Ye 和李欣，*IEEE*会士 *E*

摘要—**从隐式反馈中学习已成为现代推荐系统的标准范式。然而，这一设定始终面临假负例这一挑战：未观测到的用户-物品交互并不一定意味着负向偏好。这种模糊性往往会因曝光偏差而加剧，并可能通过提供误导性的训练信号，严重损害推荐性能。为解决这一关键问题，本文提出一种新颖且有理论依据的损失函数，称为校正加权损失（CW），它能在训练目标中系统地校正假负例的影响。我们的方法结合了两项关键技术。首先，受正例-未标记学习（PU）启发，我们通过重新校准假定的负例分布，对负采样过程进行去偏。通过利用可观测的总体数据分布（p）和正向交互分布（p^+），对真实负样本分布（p^-）进行理论近似，我们的方法能够更准确地估计抽样得到的未标记物品确为负例的可能性。其次，我们引入动态重新加权机制，根据模型当前的预测结果调整每个负例实例的重要性。该机制促使模型在正例物品与被模型自信地预测为负例（即容易负例）的物品之间施加更大的排序间隔，同时降低对不确定负例的惩罚权重，因为这类负例更有可能是假负例。我们方法的一项主要优势在于其简洁高效：它无需对数据采样过程进行复杂修改，也不会带来显著的计算开销，因此可直接应用于各种现有推荐模型。在四个大型稀疏基准数据集上进行的大量实验表明，所提出的损失具有优越性。结果显示，在多个面向排序的指标上，我们的方法始终显著优于一系列最先进的损失函数。本研究强调了在损失设计中直接解决假负例问题的重要性，并提供了一种简单而强大的解决方案。**

索引词—**推荐系统、隐式反馈、协同过滤、负采样**

尹明磊和李欣就职于奥尔巴尼大学计算机科学系，地址：纽约州奥尔巴尼，邮编 12222；电子邮箱：myin@albany.edu，xli48@albany.edu

刘斌就职于西弗吉尼亚大学管理信息系统系，地址：西弗吉尼亚州摩根敦大学大道 1601 号，邮编 26506；电子邮箱：bin.liu1@mail.wvu.edu；

龚振强就职于杜克大学电气与计算机工程系，地址：北卡罗来纳州达勒姆市邮政信箱 90291，邮编 27708；电子邮箱：neil.gong@duke.edu

Yanfang（Fanny）Ye 就职于圣母大学计算机科学与工程系，地址：印第安纳州圣母城，邮编 46556；电子邮箱：yye7@nd.edu

本研究部分由美国国家科学基金会通过 CMMI-2146076、CNS-2125958、CCSS-2348046 和 CNS-2125977 项目资助，并由西弗吉尼亚州高等教育政策委员会通过 RCG23-007 项目资助。

I. 引言

现代推荐系统已成为大型内容平台不可或缺的组成部分，通过挖掘历史用户-物品交互数据，将用户引导至可能感兴趣的物品，同时缓解信息过载。隐式反馈（如点击、点赞和购买）是用于训练推荐模型的最常见用户-物品交互数据。在隐式反馈推荐中，我们只能获取已观察到的用户-物品交互中的正样本，其余数据则未标注。推荐系统的目标是根据正样本用户-物品交互来建模用户偏好。过去十年间，表示学习的进步推动了这一领域的发展，方法从经典的矩阵分解 [1] 和神经协同过滤模型 [2]，发展到传播高阶关系信号的基于图的架构，例如用于建模用户-物品交互的神经图协同过滤和 LightGCN [3], [4]。

尽管已有许多方法被提出用于改进推荐系统中的表示学习，但对学习目标的探索却少得多。以贝叶斯个性化排序（BPR） [5],为代表的成对排序损失，凭借其在优化正负物品排序方面的简洁性和有效性，长期以来一直被广泛用作隐式反馈推荐系统中的学习目标。AdvInfoNCE [6] 通过采用困难负样本挖掘增强标准 InfoNCE 学习目标，将对比学习引入推荐系统，从而构建信息量更丰富的对比样本对。近期研究 [7] 表明，Softmax损失（SL）将完整物品集合上的正用户-物品交互归一化为多项分布，不仅能够提升推荐准确率，还能增强鲁棒性和公平性。更近的研究中，Wu等人 [8] 揭示了优化 SL 等价于对负物品执行分布鲁棒优化（DRO），并提出了双边 Softmax 损失（BSL），通过对正样本应用相同的负损失结构来改进 SL。成对 Softmax 损失（PSL） [9] 通过用更合适的激活函数替代指数形式来增强 SL，从而为折损累计增益（DCG）指标提供更紧的代理函数，并减轻假负例的影响。

然而，从隐式反馈中学习仍然受到假负例的根本性限制。这类假负例会引入有偏梯度、扭曲排序间隔，并进一步强化流行度偏差和曝光偏差。BSL [8] 和 PSL [9] 的一个关键缺陷在于，它们缺乏专门用于检测和处理假

负例的显式项或机制。它们依赖隐式重加权：BSL 利用分布鲁棒优化的数学性质对困难样本进行隐式加权，而 PSL 则利用激活函数（例如双曲正切函数）的饱和特性来控制权重分布，并限制异常值对梯度的影响。因此，这两种方法都面临着区分有价值的困难负样本与有害假负例的挑战。正如 PSL 分析 [9],所强调的，BSL 中采用的指数结构可能会无意中为那些预测分数较高的假负例分配过高的权重；在缺乏显式校正项的情况下，模型可能会对这种噪声过拟合。

本文提出了校正与加权（CW）损失，这是一种用于隐式反馈推荐的简洁、即插即用的损失函数。CW 损失通过两种互补机制处理假负例：

1)通过 PU 式去污染校正负采样。 我们将采样得到的负例重新解释为来自用户特定混合分布的样本，该混合分布由正样本和真实负例组成，并遵循正例-未标记学习 [10]的思路，推导出一个校正后的目标函数，以可处理的未标记分布与正例分布的组合取代难以处理的真实负例分布。这一步在 Softmax 式目标函数中对负例信号进行去污染，无需更改采样器，也无需进行成本高昂的密度估计。

2) 通过基于置信度的重新加权锚定正例和简单负例。 CW 损失不会像通常的做法那样强调预测为最难的负例，因为其中往往包含错误标记的正例；相反，它会为可靠的样本对（观测到的正例和得分明显较低的负例）分配更高权重，并降低不确定样本对的权重。这种带通式强调会在最容易校正的地方扩大间隔，从而提升标签噪声下排序的鲁棒性。

从概念上看，CW 损失可以视为连接带标签噪声的鲁棒分类与面向排序的协同过滤的一座简约桥梁。该方法通过修正损失以反映更纯净的负例分布，并对样本对加权，使学习聚焦于可靠区域，从而强化正负样本之间的区分，同时避免对虚假困难负例过拟合。值得注意的是，CW 损失与架构无关，可轻松融入各类推荐模型，包括矩阵分解（MF） [1], 基于图神经网络（GNN）的推荐模型 [3], 以及基于对比学习（CL）的方法 [11],，且几乎不增加计算开销，也无需更改现有采样器。

我们的贡献总结如下：

•我们识别并形式化了隐式反馈推荐中采用采样 Softmax 式训练时的假负例污染问题，并推导出一种经过 PU 校正的目标函数，以可观测分布的无偏组合替代真实负例采样分布。

• 我们设计了一种基于置信度的重新加权方案，并从理论上证明，该方案能够将学习重点放在可靠且可纠正的成对违例上，在保留判别性边际值。

• 我们在四个大规模、稀疏的基准数据集上，针对具有代表性的推荐模型（MF、LightGCN 和对比式 GNN 变体）验证了所提出的 CW 损失的有效性。

• 我们通过实证分析和消融实验量化了：(1) PU 式校正相较于标准采样目标的优势 [7], [8], [9], ；(2) 难度定向对鲁棒性的影响；以及 (3) CW 损失与最先进的自对比增强方法的兼容性[11], [6]。

总体而言，所提出的 CW 损失在普遍存在隐式反馈噪声的情况下，增强了训练目标与基于排序的评估指标之间的一致性。凭借其简洁性和广泛的兼容性，它为训练现代推荐系统提供了一种颇具吸引力的替代损失。

II. 预备知识

A. 问题设定与符号说明

我们考虑一种典型的基于协同过滤（CF）的推荐系统场景，其中包含一组用户$\mathcal{U}$ 和物品 $\mathcal{I}$，并且可以访问记录用户过往用户-物品交互的数据集 $\mathcal{D} = \{(u,\ i)\}_{u\in\mathcal{U},\ i\in\mathcal{I}}$，其中每一对 $(u,\ i) \in \mathcal{D}$ 表示用户 u 与物品 i发生了交互。具体而言，我们关注购买、点击和点赞等隐式反馈用户-物品交互。对于给定用户 u，我们将观测到的正例集合定义为$\mathcal{I}_u = \{i \in \mathcal{I} :\ (u,\ i) \in \mathcal{D}\}$；其补集 $\mathcal{I} \setminus \mathcal{I}_u$ 则视为负例。为便于后续分析，我们将$\mathcal{I}_u^-$ 记为真实负例集合，即用户 u确实不喜欢的物品集合。然而，在隐式反馈推荐场景中，界定 $\mathcal{I}_u^-$的确切边界从根本上说仍不确定。因此，对于每位用户$u \in \mathcal{U}$，唯一可观测的数据仅包括 $\mathcal{I}$ 和 $\mathcal{I}_u$，这就需要开发能够从这类不完整且含噪的反馈中推断用户偏好的方法。

因此，给定隐式反馈数据集 $\mathcal{D}$，推荐任务的目标是学习一个评分函数$r_{ui} = f_\theta(u,\ i)$: $\mathcal{U} \times \mathcal{I} \to \mathbb{R}$，以准确量化用户 u对物品 i的偏好，其中 θ 表示推荐模型的可学习参数。现代推荐系统主要采用基于嵌入的方法，其中每个用户 u 和物品 i 都被映射为 d维潜在表示，分别记为 $\mathbf{e}_u,\ \mathbf{e}_i \in \mathbb{R}^d$。随后，模型根据这些嵌入计算偏好分数。在各种偏好分数中，用户和物品嵌入的归一化内积是推荐中广泛采用且经验证有效的选择 [12]。遵循 [9],中的形式化定义，我们将每个用户—物品对 $(u,\ i)$ 的评分函数定义为 $r_{ui} = \frac{1}{2}\cdot\frac{\mathbf{e}_u\cdot\mathbf{e}_i}{\|\mathbf{e}_u\|\|\mathbf{e}_i\|}$。 最后，利用推断得到的偏好分数向用户推荐一组用户尚未接触过的物品。

此外，我们将用户u 对负样本物品 $j \in \mathcal{I} \setminus \mathcal{I}_u$ 和正样本物品 $i \in \mathcal{I}_u$ 的得分差定义为 $d_{uij} = r_{uj} - r_{ui}$，它是一个基础的排序目标，旨在优化物品的相对排序，而非其绝对得分值。

B. 面向隐式反馈推荐的 *Softmax*损失

在这项工作中，我们采用软最大损失（SL） [7], [8], [9] 作为训练推荐模型的主要优化目标。SL 的公式如下：

$$\mathcal{L}_{SL} = \mathbb{E}_{(u,i)\in\mathcal{D}} \left[-\log \left(\frac{\exp(r_{ui}/\tau)}{\sum_{j\in\mathcal{I}} \exp(r_{uj}/\tau)} \right) \right] = \mathbb{E}_{(u,i)\in\mathcal{D}} \left[\log \sum_{j\in\mathcal{I}} \exp(d_{uij}/\tau) \right], \quad (1)$$

其中， τ 表示控制 softmax分布平滑程度的温度超参数。SL 的目标是在降低负对（u, j）相对分数的同时，提高正用户-物品对（u, i）的相对分数，从而优化正样本实例相对于负样本的概率。

请注意，按照 [8], [9],中的方法，我们省略了式（1）所示 SL 公式分母中的正样本项 exp(r_{ui}/τ)，因为当负样本数量较大时，其贡献会变得微不足道。此外，近期研究结果 [13] 表明，这一修改能够改善嵌入均匀性，并在实证上取得略优的性能。

通常，在训练推荐模型 f_θ（u, i）后，我们会根据偏好分数，向用户推荐一份由其尚未体验过的热门物品组成的列表。折损累积增益（DCG） [14] 是评估推荐系统排序质量时广泛采用的评估指标。具体而言，对于每个用户 u，DCG 通过根据物品位置对相关性分数进行折损来量化排序性能。其形式化定义如下：

$$\mathrm{DCG}(u) = \sum_{i\in\mathcal{I}_u} \frac{1}{\log_2(1+\pi_u(i))}, \quad (2)$$

其中， $\pi_u(i)$表示物品 i 在用户 u的推荐列表中的排名位置。

讨论。 采用 SL 进行隐式反馈推荐的依据可以从两个互补的角度来理解。首先，理论研究已证明 SL 是 –对数 DCG 目标 [15], [9],的上界，因此优化 SL 等价于优化 DCG排序指标。其次，从优化的角度来看，最小化 SL 可视为执行分布鲁棒优化 (DRO) [16],，从而提升模型在分布偏移下的鲁棒性。

然而，这种鲁棒性是以对噪声数据更加敏感为代价的 [17], [18], ，因为 DRO 本质上会更加重视损失较大的困难实例，从而在训练过程中放大潜在噪声样本的影响训练 [8]。此外，对 SL [9] 的梯度分析表明，它会对所有负样本–正样本对隐式应用自适应加权方案，其中每个样本的梯度权重（u， i， j）与 exp(d_{uij}/τ) 成正比。尽管这一特性有利于困难样本挖掘 [7],并促进更快收敛，但也会导致假负例，

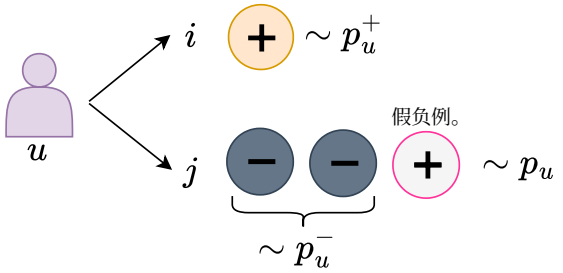

图 1：隐式反馈推荐中固有的假负例问题示意图。负物品 j 通常从用户 u未标记物品的一般分布中采样，记为 p_u。然而，该分布是由真实负例（来自底层分布 p_u^-）和假负例混合而成的。我们的工作旨在利用可观测分布 p_u 和 p_u^-，通过形式化方法近似真实负样本分布 p_u^-，以净化这一训练信号。

通常与较大的 d_{uij} 值相关联，从而获得过高的梯度权重。因此，SL 的优化过程可能会被这类假负例主导，最终导致推荐性能下降。

III. 所提出的方法

本节将介绍所提出的校正加权损失（CW），以应对上述挑战。

A. 方法概述

为减轻Softmax损失（SL）中固有的假负例所带来的不利影响，我们提出了一个双视角框架，通过分布校正和自适应加权来解决这一问题。首先，我们旨在利用每个用户的正向交互分布和总体物品分布来近似真实负样本分布，从而更忠实地估计用户特定偏好结构。其次，我们引入一种自适应加权机制，为每个采样实例分配重要性权重。该机制会动态强调置信度较高的实例（包括正样本和负样本），使模型能够关注信息性更强的样本，同时降低噪声或含糊不清的交互所产生的影响。

B. 负例采样校正

在隐式反馈推荐中，观测到的训练数据通常只包含正向交互（例如点击、浏览或购买），而没有显式负标签。如图 1 所示，这种不对称性带来了众所周知的假负例问题，因为未观测物品可能会被错误地视为负例。为应对这一挑战，我们旨在推导一种能够更忠实地近似理想无偏损失的学习目标。我们的策略是利用.....对损失进行去偏

总体物品分布 p_u、正物品分布 p_u^+ 与（未观测的）负物品分布 p_u^- 之间的关系。具体而言，借鉴正例—未标记（PU）学习 [19], [20], [21]，的视角，我们将用户特定采样分布表示为正负分量的混合：

$$p_u(i) = \tau_u^+ p_u^+(i) + \tau_u^- p_u^-(i), \tag{3}$$

其中，$p_u(i)$ 表示为用户 u 采样物品i 的一般概率。这里，$p_u^+(i)$ 和 $p_u^-(i)$ 分别表示正物品和负物品上的条件分布，系数 τ_u^+ 和 $\tau_u^- = 1 - \tau_u^+$ 对应于用户 u 随机选取的物品属于正例集或负例集的先验概率。整理公式 (3) 可得公式 $p_u^-(i) = \left(p_u(i) - \tau_u^+ p_u^+(i)\right)/\tau_u^-$，用两个易于处理的分布表示负采样分布 p_u^-；由于我们拥有来自 p_u 的样本，并且可以使用正采样分布近似来自 p_u^+ 的样本，因此这两个分布易于处理，这也是隐式反馈推荐场景中的典型做法。

根据 [9], ，我们将用户 u 的 SL（公式 1）改写为成对形式：

$$\mathcal{L}_{SL}(u) = \mathbb{E}_{i\sim p_u^+, j\sim p_u}\left[\log\left(\frac{Q}{N}\sum_j \exp(d_{uij}/\tau)\right)\right], \tag{4}$$

其中，我们引入加权参数 Q 进行分析。当负物品的数量 N 有限时，我们取$Q = N$，以与标准 softmax 损失保持一致。 $\mathcal{L}_{SL}(u)$ 的一个根本局限在于其采样过程：对于每个用户 u，索引 j 是从整个物品空间 $\mathcal{I}$上的分布 p_u中抽取的，而非从定义在真正的负物品集合 $\mathcal{I}_u^-$上的受限分布 p_u^- 中抽取。这种不匹配意味着，当 j 从 p_u中采样时，它以 τ_u^+的概率属于正例物品集合。因此，负采样的有效性会被削弱，进而可能给学习过程引入偏差。

解决这一问题的一种方法是根据式（3），用p_u 替换 p_u^-，并用 p_u^+ 替换。

引理 1. 对于固定的 Q 和 $N \to \infty$，有

$$\mathbb{E}_{i\sim p_u^+, j\sim p_u}\left[\log\left(\frac{Q}{N}\sum_j \exp(d_{uij}/\tau)\right)\right] \tag{5}$$

$$\to \mathbb{E}_{i\sim p_u^+}\left[\log\left(\frac{Q}{\tau^-}\left(\mathbb{E}_{j\sim p_u}\left[\exp(d_{uij}/\tau)\right] - \tau^+ \mathbb{E}_{k\sim p_u^+}\left[\exp(d_{uik}/\tau)\right]\right)\right)\right]. \tag{6}$$

证明。 由于 softmax 损失有界，我们可以应用控制收敛定理（DCT）来完成

证明。

$$\begin{aligned}
&\lim_{N\to\infty} \mathbb{E}\left[\log\left(\frac{Q}{N}\sum_{j=1}^{N}\exp(d_{uij}/\tau)\right)\right] \\
=&\mathbb{E}\left[\lim_{N\to\infty}\log\left(\frac{Q}{N}\sum_{j=1}^{N}\exp(d_{uij}/\tau)\right)\right] \text{(DCT)} \\
=&\mathbb{E}\left[\log\left(Q\mathbb{E}_{j\sim p_u^-}[\exp(d_{uij}/\tau)]\right)\right].
\end{aligned} \tag{7}$$

由于 $p_u^-(i) = (p_u(i) - \tau_u^+ p_u^+(i))/\tau_u^-$，且根据期望的线性性，我们有

$$\begin{aligned}
&\mathbb{E}_{j\sim p_u^-}[\exp(d_{uij}/\tau)] \\
=&\frac{1}{\tau^-}\left(\mathbb{E}_{j\sim p_u}[\exp(d_{uij}/\tau)] - \tau^+\mathbb{E}_{k\sim p_u^+}[\exp(d_{uik}/\tau)]\right)
\end{aligned} \tag{8}$$

由此完成证明。

这个极限目标仍然从 p_u中采样物品 j ，但通过额外的正例物品 v进行校正。与式（5）所示的直接目标相比，式（6）中的经验估计更容易计算。通过从 p_u 中采样 N个物品 $\{j_s\}_{s=1}^N$ ，并从 p_u^+中采样 M 个物品 $\{k_s\}_{s=1}^M$ ，我们可以估计公式（6）中的期望。

C. 置信度感知权重调整

除了考虑物品的采样分布之外，缓解隐式反馈推荐系统中假负例的另一项重要策略，是对物品进行采样后处理。一种广泛采用的方法是为采样物品分配自适应权重，以便更好地体现其相对重要性。在计算机视觉领域，Robinson 等人 [22] 通过为与锚点实例相似度更高的负例赋予更高权重，强调了困难负例在对比学习中的作用。类似地，在推荐系统中，Shi 等人[23]采用了相同原则，为偏好分数较高的负例分配更高权重。然而，[24] 最近指出，应为负例实例分配均衡且合理的权重，并警告不要过度强调高度相似的负例。这一问题在推荐系统中尤为突出，因为假负例现象尤其严重。过分强调相似度较高的负例，可能会将真正例误判为困难负例，从而误导优化过程，并进一步加剧模型退化。

在本文中，为了进一步解决假负例问题，我们提出了另一种视角：与其强调困难负例，不如专注于正例物品和能够被明确识别的（即简单的）负例。这一视角使推荐模型能够生成更加可靠、并且更符合用户真实偏好的排序列表。在隐式反馈场景中，只有正向交互会被明确观测到。随着训练的进行，模型可以逐步识别出一部分能够被确信地视为简单负例的物品。我们的方法利用这两类可信类别，即正样本和简单负例，

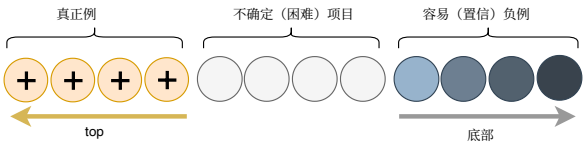

图 2：所提出的方法的排序目标。模型通过将真正例推至顶部、将置信负例推至底部来锚定排序列表。因此，包含潜在假负例的不确定项目会隐式地排在中间位置。

迭代优化排序空间。具体而言，如图2所示，这些物品充当锚点，引导不确定的（困难）物品在排序列表中处于适当位置。基于这一分析，我们定义如下加权函数：

$$w_{uij} = \exp(\beta(r_{ui} - r_{uj})), \tag{9}$$

其中 β 表示一个可调超参数，用于控制权重对分数差异的敏感度。

我们采用Softmax损失（SL）的成对形式作为推荐目标 [25], [9]。引入所提出的权重后，新的损失函数表示为：

$$\mathcal{L}_W(u) = \sum_{i \in \mathcal{I}_u} \log \left(\sum_{j \in \mathcal{I}} w_{uij}\, \sigma(d_{uij})^{1/\tau} \right), \tag{10}$$

其中，$\sigma(\cdot)$ 可以表示多种激活函数之一，包括exp、ReLU、tanh和atan [9]。在本文中，我们采用ReLU作为激活函数。这里，$d_{uij} = r_{uj} - r_{ui}$ 表示负样本与正样本之间的分数差异，τ 是一个用于控制分布平滑度的温度超参数。

从公式（10）中的损失函数可以观察到，所提出的加权方案乍看之下有些反直觉，因为它对容易样本赋予了更大的权重——这与以往工作所采用的策略相反 [23]。然而，我们认为，容易样本通常具有更高的置信度，这有助于缓解假负样本问题。整体考察公式（10）可以发现，该损失对于隐式反馈推荐表现出若干理想性质。

如图 3 所示，以 r_{ui} 和 r_{uj}为横纵坐标绘制损失曲线时，可将曲线划分为三个不同区域：（1）假负例区域；（2）不确定区域；（3）自信区域，代表模型能够正确预测正例优于负例。我们提出的损失 $\mathcal{L}_W$ 更加关注会产生较大损失的不确定实例，从而促使模型在这些模糊区域中改进预测。与以往方法不同，我们的公式不会让难样本产生过大的梯度；相反，有意义的更新主要来自易于识别且预测结果可信的样本，它们提供稳定的优化信号。此外，在对应潜在假负例的区域中，损失值会自适应降低，确保模型减少对错误标记实例的关注

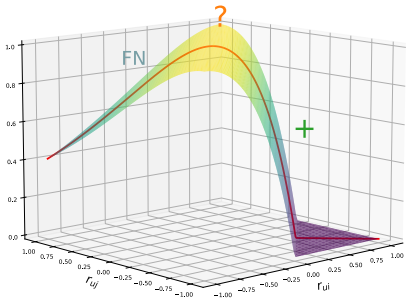

图 3：关于 r_{ui} 和 r_{uj}的损失曲线。标记为 FN 的区域表示容易出现假负例的区域。红色“? ”区域表示标签或置信度模糊的不确定实例。+ 区域对应置信区域，在该区域中推荐系统已得到有效优化。

从而减轻训练过程中假负例带来的负面影响。

理论分析。 我们从理论上证明，所提出的损失函数（记为 $\mathcal{L}_W$）是 $-\log \mathrm{DCG}(u)$ 的上界。因此，最小化 $\mathcal{L}_W$实际上等价于最大化排序指标 DCG。根据公式 10 和公式 9，损失 $\mathcal{L}_W$ 可改写为

$$\mathcal{L}_W(u) = \sum_{i \in \mathcal{I}_u} \log \left(\sum_{j \in \mathcal{I}} \exp(-\beta d_{uij})\, \sigma(d_{uij})^{1/\tau} \right). \tag{11}$$

在 $\beta \to 0^+$ 的极限情况下，所提出的损失退化为 $\mathcal{L}_{\mathrm{PSL}}$ [9]，已被严格证明是 $-\log \mathrm{DCG}$ 的上界。此外，当 $d_{uij} < 0$ 时，有 $\delta(d_{uij}) \le \exp(-\beta d_{uij})\sigma(d_{uij})$，其中 $\delta(\cdot)$ 表示 Heaviside 阶跃函数，定义为 $\delta(x) = 1$ （当 $x \ge 0$ 时），而 $\delta(x) = 0$ （其他情况）。相反，对于 $d_{uij} \ge 0$，有 $\exp(-\beta d_{uij})\sigma(d_{uij}) \le \sigma(d_{uij})$。此外，当 $d_{uij} \ge 0$ 且 $\beta \le \ln \sigma(d_{uij})^{\,d_{uij}}$ 时，可得 $\exp(-\beta \cancel{d_{uij}})\cancel{\sigma(d_{uij})} \ge \delta(d_{uij}) = 1$。由此可知，当 $0 < \beta \le \ln \sigma(d_{uij})^{\,d_{uij}}$ 时，所提出的损失 $\mathcal{L}_{\mathrm{W}}$ 是 $\delta(d_{uij})$的上界。由于 $\log_2(1+\pi_u(i)) \le \pi_u(i)$，且根据 Jensen不等式 [26]，我们有以下不等式

$$\begin{aligned} -\log \mathrm{DCG}(u) + \log |\mathcal{I}_u| &\le -\log \left(\frac{1}{|\mathcal{I}_u|} \sum_{i \in \mathcal{I}_u} \frac{1}{\pi_u(i)} \right) \\ &\le \frac{1}{|\mathcal{I}_u|} \sum_{i \in \mathcal{I}_u} \log \pi_u(i). \end{aligned} \tag{12}$$

排序位置 $\pi_u(i)$ 可表示为

$$\pi_u(i) = \sum_{j \in \mathcal{I}} \mathbb{I}\big(f(u,j) \ge f(u,i)\big) = \sum_{j \in \mathcal{I}} \delta(d_{uij}) \tag{13}$$

因此，我们可以得出以下结论：

$$-\log \mathrm{DCG}(u) \le \log \sum_{j} \delta(d_{uij}) \tag{14}$$

因此，我们提出的损失 $\mathcal{L}_W$ 作为 $-\log \mathrm{DCG}(u)$的上界，这意味着最小化该损失等价于最大化DCG排序指标。

该加权公式旨在满足以下三项关键标准：

- 正样本感知难度：负样本的难度是相对于其对应的正样本定义的。
- 与正样本分数负相关：随着关联正样本的预测分数提高，负样本的感知难度会降低，从而确保比较排序的一致性。
- 可通过超参数 β 调整：样本难度的强调程度可以灵活控制，使实践者能够在稳定性与区分能力之间取得平衡。

通过这种方式，所提出的方案确保模型能够从可靠信号中学习，同时适应不同的推荐场景。

D. 校正加权损失

结合第 III-B 节讨论的分布校正和第 III-C 节讨论的自适应加权，我们将所提出的校正加权（CW）损失函数表述如下：

$$\mathcal{L}_{\mathrm{CW}}(u) = \sum_{i \in p_u^+} \log \frac{Q}{\tau_u^-} \Big[\sum_{j \in p_u} \frac{\exp(-\beta d_{uij})}{Z} \sigma(d_{uij}) - \frac{\tau_u^+}{M} \sum_{k \in p_u^+} \sigma(d_{uik}) \Big], \tag{15}$$

其中， Z是配分函数， $\tau_u^+ = 1 - \tau_u^-$表示用户 u随机选取的一个物品属于正样本集的先验概率。我们在实验部分对这一参数进行了消融研究。 M 表示用于估计校正项的正例物品数量，而我们将 Q设为有限值 N ，用于指定采样负物品的数量。

IV. 实验

本节报告我们在四个真实世界数据集上的实验结果，以展示所提出方法的有效性。

A. 数据集

我们实验中使用的四个基准数据集汇总于表 I。在数据集预处理中，按照 [4]，中的标准做法，我们采用 10 核设置 [27],，即所有用户和物品至少有 10 次交互。我们还会移除低质量交互，例如评分（如有）低于 3 的交互。预处理后，我们将数据集划分为 80% 的训练集和 20% 的测试集。在独立同分布和噪声设置下，我们还会从训练集中随机划分出 10% 作为验证集，用于超参数调优。数据集详情如下：

- **健康 / 电子产品 / 图书 [28], [29]：** 这些数据集采集自亚马逊数据集，这是一个大规模的

表 I：本文所用数据集的统计信息。

数据集	#用户	#物品	#交互	密度
Health	1,974	1,200	48,189	0.02034
Electronic	13,455	8,360	234,521	0.00208
Gowalla	29,858	40,988	1,027,464	0.00084
Book	135,109	115,172	4,042,382	0.00026

亚马逊商品评论集合。2014年版亚马逊数据集包含 1.428 亿条评论，时间跨度为 1996 年 5 月至 2014 年 7 月。

- **Gowalla [30]：** Gowalla 数据集是一个来自基于位置的社交网络 Gowalla 的签到数据集，包含 100 万用户、100 万个地点和 600 万次签到。

B. 评估指标

我们采用 Top-K 推荐设置 [31]。评估时，会屏蔽训练集中的正例物品，并将其排除在候选池之外，从而确保仅将测试集中的正例 $\mathcal{P}_u$ 视为真实值。对于每位用户 u，我们将 Top-K 列表中被正确推荐的物品集合记为 $\mathcal{H}_u = \{i \in \mathcal{P}_u : \pi_u(i) \leq K\}$，其中 $\pi_u(i)$ 表示物品 i 的排名位置。推荐指标正式定义如下：

- 召回率@K [32]: Top-K 列表中召回的真实正例所占的比例，定义为 $\mathrm{Recall@}K(u) = |\mathcal{H}_u|/|\mathcal{P}_u|$，整体表现则由 $\mathrm{Recall@}K = \mathbb{E}_{u \sim \mathcal{U}}[\mathrm{Recall@}K(u)]$ 给出。
- 归一化折损累计增益@K [14]: K 处的折损累计增益定义为 $\mathrm{DCG@}K(u) = \sum_{i \in \mathcal{H}_u} 1/\log_2(1 + \pi_u(i))$。为考虑正例数量 $|\mathcal{P}_u|$的差异，DCG@K 通过理想 DCG@K 进行归一化，得到 $\mathrm{NDCG@}K(u) = \mathrm{DCG@}K(u)/\mathrm{IDCG@}K(u)$，其中 $\mathrm{IDCG@}K(u) = \sum_{i=1}^{\{K, |\mathcal{P}_u|\}} 1/\log_2(1+i)$。总体得分为 $\mathrm{NDCG@}K = \mathbb{E}_{u \sim \mathcal{U}}[\mathrm{NDCG@}K(u)]$。

C. 推荐骨干模型

推荐骨干模型（又称推荐模型）是推荐系统（RS）的核心组成部分。在本文中，推荐骨干模型可正式定义为偏好评分函数 $r_{ui} : \mathcal{U} \times \mathcal{I} \to \mathbb{R}$ ，由 Θ 参数化，其中 $\mathcal{U}$ 和 $\mathcal{I}$ 分别表示用户空间和物品空间。评估所提出的推荐损失在多种不同骨干模型上的表现，对于验证其鲁棒性、泛化能力和一致性至关重要。

在我们的实验框架中，我们考虑了三种具有代表性的推荐骨干模型，它们在架构设计和建模假设方面各不相同：

- **矩阵分解（MF） [1]：** MF 是一种基础且效果显著的推荐方法，它将用户-物品交互矩阵分解为潜在的用户和物品表示。许多基于嵌入的模型都将 MF 作为表示学习的基础层。根据 [4] 和 [9],，我们将

所有实验配置中的嵌入维度均设为 $d = 64$ 。

• **LightGCN [3]：** LightGCN 是一种基于图的推荐模型，通过在用户—物品二部图上执行图卷积操作来扩展协同过滤。通过移除神经图协同过滤中的特征变换和非线性激活组件，LightGCN 仅保留必要的邻域聚合机制。遵循 [3] 和 [9], 中的原始设置，我们采用两层架构。

•**XSimGCL [11]：** XSimGCL 在三层 LightGCN 主干网络之上引入了对比学习范式 [33], [34] 。它向逐层嵌入中注入随机扰动，并通过辅助 InfoNCE 损失 [35], 对最后一层与第 l^*个中间层施加对比正则化。与 [11] 和 [9], 一致，我们将扰动幅度设为 0.1，设置 $l^* = 1$（将嵌入层视为第 0 层），使用 0.1 的温度参数，并从 $\{0.05, 0.1, 0.2\}$ 中选取辅助 InfoNCE 损失的权重。

D. 基线推荐损失

为了全面评估所提出损失函数的有效性，我们复现了多种最先进的推荐损失，并通过网格搜索确定其最优超参数。在损失优化中，我们采用 Adam 优化器 [36], 并设置两个可调超参数：学习率（lr）和权重衰减（wd）。批量大小固定为 1024，训练进行 200 个 epoch，在此期间观察到所有对比方法均已收敛。当需要进行负采样时，负样本数设为 $N = 1000$；对于 MovieLens 数据集，由于其物品集规模较小，负样本数则减少至 200。这些配置与 [9] 报告的实验设置一致。对比方法及其相应超参数搜索空间的详情总结如下：

• **贝叶斯个性化排序 [5]。** 贝叶斯个性化排序是一种基于贝叶斯最大似然估计（最大似然估计）的传统成对损失 [37]。贝叶斯个性化排序旨在学习物品之间的偏序，即正例物品的排名应高于负物品。此外，贝叶斯个性化排序是 AUC 指标的替代损失 [5], [38]。贝叶斯个性化排序中的评分函数 r_{ui} 定义为用户和物品嵌入之间的点积。

• **LLPAUC [39]。** LLPAUC 是一种针对 AUC 左下部分设计的替代损失。研究表明，它可作为 Top-K 指标（例如召回率@K和精确率@K [39]）的替代损失 [32]。LLPAUC 中的评分函数 r_{ui} 定义为用户和物品嵌入之间的余弦相似度。

• **软最大损失 (SL) [7]。** SL 是一种最先进的推荐损失，源自列表式最大似然估计 (MLE)。除了从最大似然估计或对比学习的角度解释 SL 的有效性之外，已有研究证明，SL 可作为折损累积增益的代理函数损失。具体而言，SL 是 –log DCG[15], [9], 的上界，因此优化 SL 与优化 DCG 是一致的。在实践中，SL 引入温度超参数 τ ，用于控制 softmax 运算符的平滑度。SL 中的评分函数 r_{ui} 定义为用户和物品嵌入之间的余弦相似度。

• **AdvInfoNCE [6]。** AdvInfoNCE 是基于分布鲁棒优化（DRO） [16]对 SL 所做的改进。它在 SL 的成对评分差 d_{uij} 中引入了自适应负样本难度。尽管这种改进可能增强鲁棒性，但也会扩大损失与折损累积增益优化目标之间的差距，从而可能导致性能欠佳 [9]。在实际实现中，按照 [6], 中的原始设置，负样本权重固定为 64，每 5 个周期进行一次对抗学习，并将对抗学习率设为 5×10^{-5}。AdvInfoNCE 中的评分函数 r_{ui} 定义为用户和物品嵌入之间的余弦相似度。

• **BSL [8]。** BSL 是一种基于分布鲁棒优化的 Softmax损失改进方法，对正样本实例应用额外的分布鲁棒优化。它引入了两个温度超参数， τ_1 和 τ_2。当 $\tau_1 = \tau_2$时，BSL 等价于 Softmax损失。BSL 中的评分函数 r_{ui} 定义为用户和物品嵌入之间的余弦相似度。

• **PSL [9]。** PSL 是一种 NDCG 替代损失，它通过用更合适的激活函数替换指数函数，对 Softmax损失进行了泛化。 [9] 证明，PSL 建立的 –log DCG 上界比 Softmax损失更紧，从而带来了最先进的推荐性能。此外，PSL 不仅保留了 Softmax损失在分布鲁棒优化鲁棒性方面的优势，还增强了对假负例的抗噪能力。PSL 也具有较高的超参数效率，仅需一个温度超参数 τ 即可控制梯度的平滑程度。PSL 中的评分函数 s_{ui} 定义为用户和物品嵌入之间的一半余弦相似度。

• **SL@K [25]。** SL@K 是本研究提出的一种折损累积增益@K 代理损失。形式上，SL@K 是一种加权 SL，其权重为 $w_{ui} = \sigma_w(r_{ui} - \beta_u^K)$，其中 β_u^K是用户 u对所有物品的偏好分数中排名前K分位数的分数，σ_w 是一种激活函数（例如 Sigmoid 函数）。直观而言，权重 w_{ui} 旨在强调排名前K 的物品在梯度中的重要性，从而提升排名前K 物品的推荐性能。与传统 SL 相比，SL@K 引入了多个超参数，包括用于基于分位数的权重的温度超参数 τ_w 、用于 SL 损失项的温度超参数 τ_d 以及分位数更新间隔 T_β。在实践中， τ_d 可以直接设为 SL 的最优温度 τ 。SL@K 中的评分函数 r_{ui}定义为用户和物品嵌入之间的余弦相似度。

E. 性能比较

表 II 报告了所提出的正确性与加权（CW）损失在四个广泛使用的

表 II：我们提出的损失（CW）与现有损失函数之间的前20名推荐性能比较。最佳结果以粗体突出显示，最佳基线性能加下划线。“改进幅度”表示我们的损失相对于最佳基线的性能提升。

骨干网络	Loss	Health		Electronic		Gowalla		Book	
		召回率	NDCG	召回率	NDCG	召回率	NDCG	召回率	NDCG
MF	BPR	0.1627	0.1234	0.0816	0.0527	0.1355	0.1111	0.0665	0.0453
	LLPAUC	0.1644	0.1209	0.0821	0.0499	0.1610	0.1189	0.1150	0.0811
	SL	0.1719	0.1261	0.0821	0.0529	0.2064	0.1624	0.1559	0.1210
	AdvInfoNCE	0.1659	0.1237	0.0829	0.0527	0.2067	0.1627	0.1557	0.1172
	BSL	0.1719	0.1261	0.0834	0.0530	0.2071	0.1630	0.1563	0.1212
	PSL	0.1718	0.1268	0.0838	0.0541	0.2089	0.1647	0.1569	0.1227
	SL@K	0.1823	0.1390	0.0901	0.0590	0.2121	0.1709	0.1612	0.1269
	CW（本文方法）	**0.1908**	**0.1481**	**0.0938**	**0.0618**	**0.2142**	**0.1747**	**0.1634**	**0.1298**
	提升百分比	**+4.71%**	**+6.54%**	**+4.11%**	**+4.76%**	**+1.01%**	**+2.25%**	**+1.35%**	**+2.33%**
LightGCN	BPR	0.1618	0.1203	0.0813	0.0524	0.1745	0.1402	0.0984	0.0678
	LLPAUC	0.1685	0.1207	0.0831	0.0507	0.1616	0.1192	0.1147	0.0810
	SL	0.1691	0.1235	0.0823	0.0526	0.2068	0.1628	0.1567	0.1220
	AdvInfoNCE	0.1706	0.1264	0.0823	0.0528	0.2066	0.1625	0.1568	0.1177
	BSL	0.1691	0.1236	0.0823	0.0526	0.2069	0.1628	0.1568	0.1220
	PSL	0.1701	0.1270	0.0830	0.0536	0.2086	0.1648	0.1575	0.1233
	SL@K	0.1783	0.1371	0.0903	0.0591	0.2128	0.1729	0.1625	0.1280
	CW（本文方法）	**0.1827**	**0.1454**	**0.0971**	**0.0633**	**0.2154**	**0.1783**	**0.1662**	**0.1306**
	提升百分比	**+2.49%**	**+6.07%**	**+7.46%**	**+7.17%**	**+1.22%**	**+3.14%**	**+2.28%**	**+2.04%**
XSimGCL	BPR	0.1496	0.1108	0.0777	0.0508	0.1966	0.1570	0.1269	0.0905
	LLPAUC	0.1519	0.1083	0.0781	0.0481	0.1632	0.1200	0.1363	0.1008
	SL	0.1534	0.1113	0.0772	0.0490	0.2005	0.1570	0.1549	0.1207
	AdvInfoNCE	0.1499	0.1072	0.0776	0.0489	0.2010	0.1564	0.1568	0.1179
	BSL	0.1649	0.1201	0.0800	0.0507	0.2037	0.1597	0.1550	0.1207
	PSL	0.1579	0.1143	0.0801	0.0507	0.2037	0.1593	0.1571	0.1228
	SL@K	0.1753	0.1332	0.0869	0.0571	0.2095	0.1717	0.1624	0.1277
	CW（本文方法）	**0.1796**	**0.1396**	**0.0903**	**0.0600**	**0.2120**	**0.1792**	**0.1655**	**0.1306**
	提升百分比	**+2.43%**	**+4.85%**	**+3.94%**	**+5.14%**	**+1.21%**	**+4.36%**	**+1.92%**	**+2.27%**

基准数据集：Gowalla、Book、Health 和 Electronic 上的 Top-20 性能，涵盖三种具有代表性的模型架构：矩阵分解（MF）、LightGCN 和 XSimGCL。在所有配置中，CW 均表现出相较于现有去偏损失的明显且稳定的提升，彰显了其普适性，以及与浅层和基于图的协同过滤模型的兼容性。

对于矩阵分解骨干网络，CW 在 Health 和 Electronic数据集上取得了最大的绝对提升。具体而言，与最强竞争基线相比，CW 在 Health 上将 NDCG@20 提高了 6.5%，在 Electronic 上提高了 4.8%。在Gowalla 和 Book 数据集上，CW 也取得了适中但稳定的提升，NDCG@20 分别提高了 2.3% 和 2.2%。这些结果表明，即使不显式建模用户—物品图结构，CW 也能有效缓解稀疏隐式反馈场景中常见的假负例偏差。

对于 LightGCN，CW 在所有数据集上都带来了显著且稳定的收益。在 Electronic 数据集上，CW 的提升最为显著，召回率@20 和 NDCG@20 分别提高了约 7.5% 和 7.2%。在 Health 数据集上，CW 的 NDCG@20 比最佳基线高出 6.0%，同时在 Gowalla（3.1%）和 Book（2.0%）上也保持稳定提升。这种稳定的改进表明将损失层去偏与消息传递架构相结合，能够使模型学习到更可靠的物品嵌入，并在用户-物品图中传播偏差更小的信号。

与对比学习骨干网络 XSimGCL 结合时，CW 仍能取得有竞争力的结果。尽管 XSimGCL 已采用自监督目标来提升表示质量，CW 仍使 Health 上的 NDCG@20 提高了 4.9%，使 Electronic 上提高了 5.1%，同时在 Gowalla 和 Book 上也带来了较小但一致的提升（均约为 2.3%）。这一观察表明，CW 的去偏效果与自监督正则化相辅相成，并且能够在目标函数层面进一步降低排序偏差，超越基于增强的对比学习所能达到的效果。

总体而言，所有模型架构和数据集上的结果都凸显了 CW 的鲁棒性。性能提升并不局限于特定模型或数据领域，这证实了在损失层面校正假负例，并为单个实例分配自适应置信度权重，能够共同带来稳定的 top-K 排序提升。这种稳定性凸显了 CW 作为传统隐式反馈推荐中基于 softmax 的排序损失即插即用替代方案的潜力。

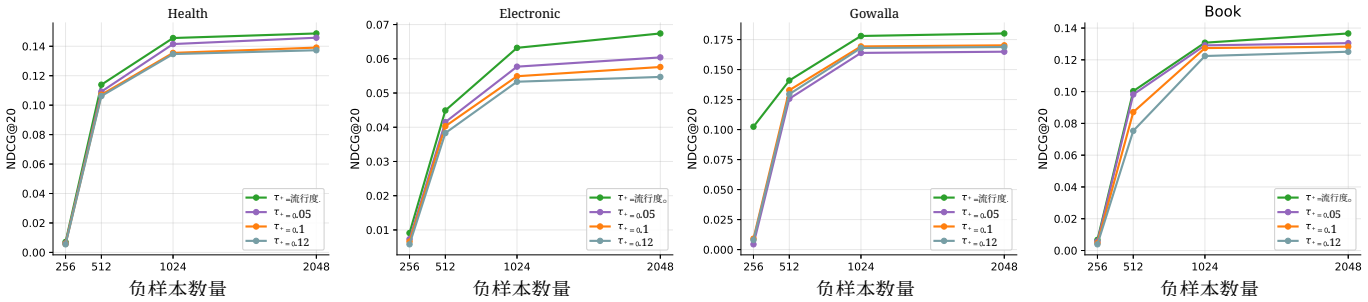

图4：使用 LightGCN 作为推荐模型时，在不同 τ^+ 取值下所提出损失的 NDCG@20 性能。术语 pop. 表示 τ^+ 是根据物品流行度计算的。

F. 消融研究

为了更好地理解 CW 中各个组件的作用，我们围绕两个主要方面开展了一系列消融实验：（1）利用正例-未标记（PU）形式重新平衡负例分布的校正项；（2）基于训练对的可靠性估计自适应调整梯度的置信度感知加权。

表III：四个数据集上的不同损失因子（指标：NDCG@20，模型：LightGCN）。

	$\mathcal{L}_{\mathrm{SL}}$	$\mathcal{L}_{\mathrm{PSL}}$	$\mathcal{L}_{\mathrm{C}}$	$\mathcal{L}_{\mathrm{W}}$	$\mathcal{L}_{\mathrm{CW}}$
Health	0.1235	0.1270	0.1243	0.1279	0.1454
Electronic	0.0526	0.0536	0.0529	0.0553	0.0633
Gowalla	0.1628	0.1648	0.1632	0.1657	0.1783
Book	0.1220	0.1233	0.1225	0.1261	0.1306

表 III 展示了使用 LightGCN 主干网络、采用五种损失变体得到的结果：标准 softmax 损失（记为 $\mathcal{L}_{SL}$）、其成对形式（$\mathcal{L}_{PSL}$）、仅校正项（L_C）、仅加权（$\mathcal{L}_W$），以及完整组合（$\mathcal{L}_{CW}$）。结果呈现出两个一致的规律。首先，在所有数据集上，L_C 和 $\mathcal{L}_W$均优于 $\mathcal{L}_{SL}$ 和 $\mathcal{L}_{PSL}$，这表明校正项成功消除了假负例造成的污染，而加权方案则通过强调可信的正负样本对来稳定优化。其次，在 L_{CW} 中同时应用这两种机制时，性能进一步提升，并在每种设置下都取得最佳结果。例如，在 Electronic 数据集上，NDCG@20 从 0.0526（使用 $\mathcal{L}_{SL}$）提升至 0.0633（使用 $\mathcal{L}_{CW}$）；在 Health 数据集上，则从 0.1235 提升至 0.1454。这些增益具有叠加性，说明这两个组件针对的是不同但互补的偏差来源。

我们进一步考察了 CW 对正例先验 τ_u^+ 的敏感性，该先验表示对每个用户而言，被观测到的物品中实际为正样本的估计比例。如图4所示，CW 在较宽的 τ^+ 取值范围内（尤其是 0.05 至 0.12 之间）以及采用数据驱动的基于流行度的估计时，均保持稳健。从这一分析中可以得出几点见解。首先，CW 表现出较强的稳定性：随着 τ^+变化，性能平缓且幅度较小地变化，这表明该方法无需精确的先验估计也能有效运行。其次，适度的先验（约为 0.1–0.12）往往比非常

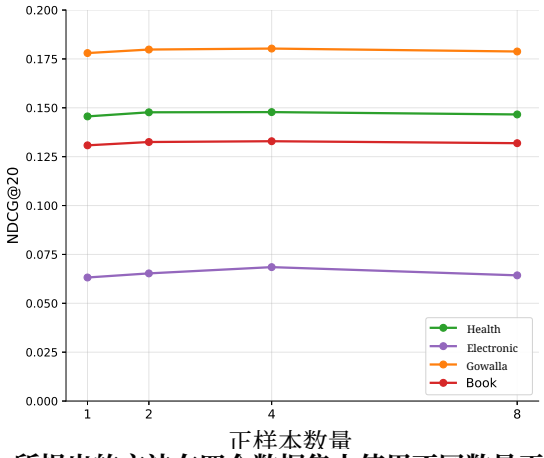

图 5：所提出的方法在四个数据集上使用不同数量正样本的比较。结果基于 LightGCN 模型。

小的值表现略好，这表明过于保守的先验可能会导致校正不足。第三，基于流行度的先验表现与固定常数相当，甚至略胜一筹，为根据数据集偏斜自适应调整校正强度提供了一种简单且无需超参数的方法。

我们还分析了修正目标中每位用户所用正样本数量的影响。如图 5 所示，随着纳入更多正例物品，NDCG@20 持续提升，并在正样本数量约为 4 个后趋于饱和。这一发现表明，CW 能够从更丰富的正向监督中获益，同时仍保持高效，因为每位用户只需少量正样本，就足以实现显著的去偏效果。

图 6 展示了在四个基准数据集上，采用 LightGCN 主干网络时，超参数 β 对模型性能的敏感性分析。β 的取值决定了损失函数的侧重点：当 $\beta \to 0$时，所提出损失函数中的加权部分退化为标准 PSL 损失；相反，随着 β 增大，模型会更加重视困难（不确定或错误）负例。因此，优化 β 的关键在于平衡对信息丰富的困难负例进行有效挖掘，与抵御训练数据中潜在噪声和离群值、保持鲁棒性这两者。实验结果显示，当 β 从 0.2 增至

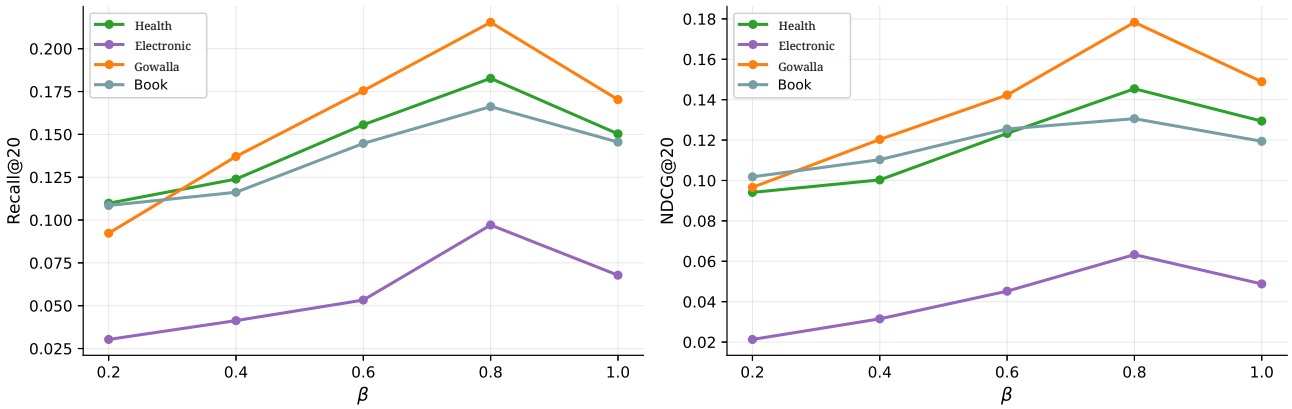

图6：基于 LightGCN 模型，在四个数据集上比较所提出的方法在不同 β 值下的表现。

0.8 时，Recall@20 和 NDCG@20 均呈现稳定的上升趋势，表明适度提高困难负样本权重能够增强模型捕捉潜在用户偏好的能力，并提升整体排序质量。然而，当 β 超过 0.8 时，模型性能有所下降。这表明，过度强调不确定负例可能导致过拟合或放大噪声，从而损害推荐准确率。从数据集表现来看，*Gowalla* 提升最为显著，其次是 *Health*和*Book*，而*Electronic*的提升相对较小。综合来看，$\beta \approx 0.8$ 取中间值时，能够在推荐准确率与模型泛化能力之间实现最佳权衡。

总而言之，消融研究提供了有力的实证证据，表明：(1) 校正项能够有效抵消假负例污染；(2) 置信度感知的加权机制优先考虑信息性样本，并增强优化稳定性；(3) 两种机制的结合产生了稳健且具有良好泛化能力的损失函数。这些发现解释了主要实验中观察到的持续改进，并验证了 CW 作为一种实用且具有理论依据的隐式反馈推荐模型增强方法的有效性。

V. 相关工作

我们的工作与推荐模型及推荐系统的目标函数相关。

A. 推荐模型

过去二十年来，推荐系统中的协同过滤（CF）建模领域发生了显著演变，从浅层线性方法稳步发展到表达能力强大的基于图的架构。早期研究主要采用基于矩阵分解（MF）的方法 [1]，这些方法奠定了基础，将用户和物品表示在潜在空间中，并通过内积捕捉偏好信号。矩阵分解的扩展引入了日益复杂的机制，以更好地捕捉潜在的用户—物品关系 [40]。经典模型包括 SVD [41], [42],SVD ++ [43]、LRML [44], 和 NCF [2], , 它们逐步增强了交互建模能力，同时保持了计算上的可扩展性。这些方法展示了基于嵌入的表示如何紧凑地编码协同信号，从而为后续创新奠定了理论和实践基础。

与此同时，图神经网络（GNN）的迅速兴起为协同过滤研究开辟了新的机遇。由于协同过滤本质上假设用户与物品通过高阶关系结构（例如共享偏好或共同消费模式）相连，因此，图神经网络的归纳偏置与这一问题设定天然契合 [45], [46], [47], [4], [48]‚[49], [50]。由此，新一代基于图神经网络的协同过滤模型应运而生，包括神经图协同过滤 [4]、LightGCN [3]、LCF [51], 和 APDA [52]。这些方法系统地利用高阶邻域聚合来优化用户和物品嵌入，因此性能优于传统的基于分解的技术。

在 LightGCN 的结构创新基础上，研究人员还将对比学习引入协同过滤，这主要源于对比学习在表示学习方面的有效性 [34]‚[35]。对比目标提供自监督信号，通过基于图的数据增强促进稳健的嵌入学习。SGL [53] 和 XSimGCL [11]等模型代表了这一研究方向，它们将图神经网络架构与对比正则化相结合，取得了最先进（SOTA）的结果。总的来说，这一发展脉络体现了协同过滤研究从基于矩阵的潜在因子分解向基于图的自监督范式转变，也凸显了研究者持续追求更丰富的交互建模、更强的泛化能力，以及在大规模推荐环境中的可扩展性。

B. 推荐系统的目标函数

尽管推荐模型已经得到了充分研究，但推荐系统的学习目标却鲜有探索。推荐损失大致可分为三类典型类别：逐点损失 [2], [54], , 将推荐视为针对观测交互的回归或分类任务；成对损失 [5], , 优化正负样本对之间的相对排序；以及基于 Softmax 的损失（SL） [7]„ 采用类似分类的视角，将正用户-物品交互在全部物品上的分布归一化为多项式分布。

通过将正样本用户-物品交互归一化为完整物品集上的多项分布，类似于视图。

具体而言，由于成对排序损失 [5]在优化正负物品排序方面简单且有效，因此长期以来一直被广泛用作隐式反馈推荐系统中的学习目标。Shi 等人 [39]没有优化正负物品排序，而是开发了 LLPAUC，这是一种有理论依据的代理函数，用于近似不可微的召回率@K 指标。在标准 InfoNCE目标的基础上，该目标为每个正样本采样一部分负样本，AdvInfoNCE [6] 通过信息丰富的困难负采样采用对比学习进行推荐。

近年来，基于 Softmax 的损失（SL） [7] 在实践中已显现出尤为出色的效果，部分原因在于其能够利用完整列表信息并提供平滑的梯度。鉴于 SL 的优势，近期研究 [8], [9], [25]从不同角度对其进行了改进。Wu 等人 [8]证明，SL 优化对应于针对负样本的分布鲁棒优化（DRO），并提出双边 Softmax 损失（BSL），通过对正样本对称化损失来增强 SL。Yang 等人[9] 提出成对 Softmax 损失（PSL），这是 SL 的一种扩展，以替代性的激活函数取代指数形式；研究表明，与折损累积增益（DCG）指标相比，它是更紧的代理函数，并且对假负例更具鲁棒性。为直接优化 Top-K 排序指标归一化折损累计增益@K，Softmax损失@K [25] 将其松弛为一种基于 Softmax 的损失的平滑替代损失。

这些研究表明，学界逐渐达成共识：SL 是一种灵活的骨干网络目标，但仍需针对特定挑战进行谨慎调整，例如提升对假负例的鲁棒性，以及更好地优化推荐性能（如排序指标）。与增强隐式推荐中基于 Softmax 的损失的研究不同，所提出的校正与加权（CW）损失通过利用可观测的总体数据分布和正向交互分布来近似真实负样本分布，从而对负采样过程进行去偏。同时，CW 损失通过动态重新加权机制，鼓励正例物品与置信度较高的预测负例之间形成更大的排序间隔，同时自适应地减轻对不确定负例的惩罚，因为这类负例更有可能是假负例，从而提升排序性能。

VI. 结论与未来工作

本文提出了校正与加权（CW）损失，这是一种简单而有效的隐式反馈推荐损失函数。不同于依赖复杂采样启发式方法或辅助建模假设的现有方法，CW 通过将观测到的反馈分解为正例与未标记部分，并根据训练实例的可靠性对其加权，直接校正损失本身。这种设计同时应对了隐式推荐领域长期存在的两项挑战：未观测物品中的假负例污染，以及将所有实例视为同等重要所导致的不稳定性。

在四个基准数据集和多种骨干网络（包括矩阵分解、LightGCN 和 XSimGCL）上进行的大量实验表明，CW 的表现始终优于具有代表性的最先进损失函数。实验结果证实：(1) 校正能有效重新平衡标签噪声分布；(2) 置信度加权通过聚焦于可信区域，使优化过程更加稳定；(3) 二者结合后，能够适用于不同架构和数据场景。消融分析还进一步证实，CW 对正例先验、负采样规模以及每位用户观测到的正例数量变化均保持稳健，表明其适用于大规模真实场景部署。

除了在实证性能上的表现，CW 还为隐式反馈去偏提供了一种在概念上统一的视角。CW 并未改变模型结构或引入外部偏差估计器，而是将学习目标重新诠释为正例-未标记数据假设下的估计校正风险最小化问题。这一联系在理论上更加清晰，并凸显了损失层面的校正可以作为基于模型的去偏策略的一种轻量而有效的替代方案。

尽管 CW 已取得出色成果，仍有若干方向有待未来探索。首先，当前的表述假设潜在正例的先验在不同用户之间相互独立，而在用户异质性较强的领域中，这一假设可能并不成立。未来的扩展工作可以探索基于用户交互历史或侧信息估计的个性化或自适应先验。其次，虽然我们的分析聚焦于静态推荐，但将 CW 纳入动态推荐或基于会话的推荐框架，或许能进一步揭示其在用户偏好不断变化时的潜力。第三，可以将置信度加权机制扩展为能够感知不确定性的方法，或结合贝叶斯建模，从而为收敛和泛化提供理论保证。最后，将 CW 与强化学习或基于多臂老虎机的推荐范式相结合，或许能为如何将去偏与长期奖励优化相结合带来新的见解。

参考文献

[1] Y. Koren、R. Bell 和 C. Volinsky，“推荐系统中的矩阵分解技术”，*Computer*，第42卷第8期，第30–37页，2009年。[2] X. He、L. Liao、H. Zhang、L. Nie、X. Hu 和 T.-S. Chua，“神经协同过滤”，载于第*26*届国际万维网大会论文集，2017年，第173–182页。[3] X. He、K. Deng、X. Wang、Y. Li、Y. Zhang 和 M. Wang，“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，2020年，第639–648页。[4] X. Wang、X. He、M. Wang、F. Feng 和 T.-S. Chua，“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，2019年，第165–174页。[5] S. Rendle、C. Freudenthaler、Z. Gantner 和 L. Schmidt-Thieme，“BPR：基于隐式反馈的贝叶斯个性化排序”，载于第二十五届人工智能不确定性会议论文集，2009年，第452–461页。[6] A. Zhang、L. Sheng、Z. Cai、X. Wang 和 T.-S. Chua，“以有原则的对抗对比损失增强协同过滤”，《神经信息处理系统进展》，第36卷，2024年。[7] J. Wu、X. Wang、X. Gao、J. Chen、H. Fu 和 T. Qiu，“采样Softmax损失对物品推荐的有效性研究”，*ACM*信息系统汇刊，第42卷第4期，第1–26页，2024年。

[8] J. Wu、J. Chen、J. Wu、W. Shi、J. Zhang 和 X. Wang，“BSL：理解并改进用于推荐的Softmax损失”，载于2024年第40届IEEE国际数据工程会议（ICDE）。IEEE，2024年，第816–830页。[9] W. Yang、J. Chen、X. Xin、S. Zhou、B. Hu、Y. Feng、C. Chen 和 C. Wang，“PSL：从成对视角重新思考并改进用于推荐的Softmax损失”，《神经信息处理系统进展》，第37卷，第120 974–121 006页，2024年。[10] C.-J. Hsieh、N. Natarajan 和 I. Dhillon，“用于矩阵补全的正例-未标记学习”，载于《国际机器学习会议》。PMLR，2015年，第2445–2453页。[11] J. Yu、X. Xia、T. Chen、L. Cui、N. Q. V. Hung 和 H. Yin，“XSimGCL：迈向极简的推荐图对比学习”，《IEEE知识与数据工程汇刊》，第36卷第2期，第913–926页，2023年。[12] J. Chen、J. Wu、J. Wu、X. Cao、S. Zhou 和 X. He，“Adap-τ：自适应调节推荐中的嵌入幅度”，载于《2023年ACM网络会议论文集》，2023年，第1085–1096页。[13] C.-H. Yeh、C.-Y. Hong、Y.-C. Hsu、T.-L. Liu、Y. Chen 和 Y. LeCun，“解耦对比学习”，载于《欧洲计算机视觉会议》。Springer，2022年，第668–684页。[14] K. J¨arvelin 和 J. Kek¨al¨ainen，“检索高度相关文档的信息检索评估方法”，载于《ACM SIGIR论坛》，第51卷第2期。ACM，纽约州，美国纽约，2017年，第243–250页。[15] S. Bruch、X. Wang、M. Bendersky 和 M. Najork，“采用二元相关性进行学习排序的softmax交叉熵损失分析”，载于《2019年ACM SIGIR信息检索理论国际会议论文集》，2019年，第75–78页。[16] A. Shapiro，“分布鲁棒随机规划”，《SIAM优化杂志》，第27卷第4期，第2258–2275页，2017年。[17] S. Nietert、Z. Goldfeld 和 S. Shafiee，“离群点鲁棒Wasserstein分布鲁棒优化”，《神经信息处理系统进展》，第36卷，2024年。[18] R. Zhai、C. Dan、Z. Kolter 和 P. Ravikumar，“Doro：分布鲁棒与离群点鲁棒优化”，载于《国际机器学习会议》。PMLR，2021年，第12 345–12 355页。[19] C. Elkan 和 K. Noto，“仅利用正例与未标记数据学习分类器”，载于《第14届ACM SIGKDD知识发现与数据挖掘国际会议论文集》，2008年，第213–220页。[20] M. C. Du Plessis、G. Niu 和 M. Sugiyama，“正例与未标记数据学习分析”，《神经信息处理系统进展》，第27卷，2014年。[21] C.-Y. Chuang、J. Robinson、Y.-C. Lin、A. Torralba 和 S. Jegelka，“去偏对比学习”，《神经信息处理系统进展》，第33卷，第8765–8775页，2020年。[22] J. D. Robinson、C.-Y. Chuang、S. Sra 和 S. Jegelka，“使用困难负样本的对比学习”，载于《国际学习表征会议》，2021年。 [在线]。获取地址：https: //openreview.net/forum?id=CR1XOQ0UTh-[23] W. Shi、J. Chen、F. Feng、J. Zhang、J. Wu、C. Gao 和 X. He，“推荐中困难负采样背后的理论研究”，载于《2023年ACM网络会议论文集》，2023年，第812–822页。[24] J. Wu、J. Chen、J. Wu、W. Shi、X. Wang 和 X. He，“通过分布鲁棒优化理解对比学习”，《神经信息处理系统进展》，第36卷，23 320，2023年23 297页。[25] W. Yang、J. Chen、S. Zhang、P. Wu、Y. Sun、Y. Feng、C. Chen 和 C. Wang，“突破top-k瓶颈：推进推荐系统中的top-k排序指标优化”，载于《第31届ACM SIGKDD知识发现与数据挖掘会议论文集》第2卷，2025年，第3542–3552页。[26] J. L. W. V. Jensen，“论凸函数及平均值之间的不等式”，《数学学报》，第30卷，1906年，第175页。[27] R. He 和 J. McAuley，“VBPR：基于隐式反馈的视觉贝叶斯个性化排序”，载于《AAAI人工智能会议论文集》，第30卷第1期，2016年。[28] ——，“起伏变化：利用单类协同过滤对时尚趋势的视觉演变进行建模”，载于《第25届国际万维网大会论文集》，2016年，第507–517页。[29] J. McAuley、C. Targett、Q. Shi 和 A. Van Den Hengel，“风格与替代品的基于图像的推荐”，载于《第38届国际ACM SIGIR信息检索研究与发展会议论文集》，2015年，第43–52页。[30] E. Cho、S. A. Myers 和 J. Leskovec，“友谊与移动：基于位置的社交网络中的用户移动”，载于《第17届ACM SIGKDD知识发现与数据挖掘国际会议，2011年，第1082–1090页。[31] T.-Y. Liu等，“面向信息检索的学习排序”，信息检索基础与趋势®，第3卷，第3期，第225–331页，2009年。[32] Z. Fayyaz、M. Ebrahimian、D. Nawara、A. Ibrahim和R. Kashef，“推荐系统：算法、挑战、指标与商业机会”，《应用科学》，第10卷，第21期，第7748页，2020年。[33] A. Jaiswal、A. R. Babu、M. Z. Zadeh、D. Banerjee和F. Makedon，“对比自监督学习综述”，技术，第9卷，第1期，第2页，2020年。[34] X. Liu、F. Zhang、Z. Hou、L. Mian、Z. Wang、J. Zhang和J. Tang，“自监督学习：生成式还是对比式”，IEEE知识与数据工程汇刊，第35卷，第1期，第857–876页，2021年。[35] A. v. d. Oord、Y. Li和O. Vinyals，“基于对比预测编码的表示学习”，arXiv预印本arXiv:1807.03748，2018年。[36] D. P. Kingma和J. Ba，“Adam：一种随机优化方法”，arXiv预印本arXiv:1412.6980，2014年。[37] G. Casella和R. Berger，《统计推断》。CRC出版社，2024年。[38] T. Silveira、M. Zhang、X. Lin、Y. Liu和S. Ma，“推荐系统的表现如何？推荐评估综述”，《国际机器学习与控制论杂志》，第10卷，第813–831页，2019年。[39] W. Shi、C. Wang、F. Feng、Y. Zhang、W. Wang、J. Wu和X. He，“左下部分AUC：一种有效且高效的推荐优化指标”，arXiv预印本arXiv:2403.00844，2024年。[40] E. Fiesler和R. Beale，《神经计算手册》。CRC出版社，2020年。[41] S. Deerwester、S. T. Dumais、G. W. Furnas、T. K. Landauer和R. Harshman，“通过潜在语义分析进行索引”，《美国信息科学学会杂志》，第41卷，407，1990年6，391第。第–页。[42] R. Bell、Y. Koren和C. Volinsky，“通过对大型推荐系统进行多尺度关系建模来提高准确率”，载于《第13届ACM SIGKDD知识发现与数据挖掘国际会议论文集》，2007年，第95–104页。[43] Y. Koren，“因子分解与邻域相结合：一种多面向的协同过滤模型”，载于《第14届ACM SIGKDD知识发现与数据挖掘国际会议论文集》，2008年，第426–434页。[44] Y. Tay、L. Anh Tuan和S. C. Hui，“基于记忆的注意力，通过潜在关系度量学习实现协同排序”，载于《2018年万维网大会论文集》，2018年，第729–739页。[45] S. Wu、F. Sun、W. Zhang、X. Xie和B. Cui，“推荐系统中的图神经网络：综述”，《ACM计算调查》，第55卷，第5期，第1–37页，2022年。[46] C. Gao、X. Wang、X. He和Y. Li，“用于推荐系统的图神经网络”，载于《第15届ACM网络搜索与数据挖掘国际会议论文集》，2022年，第1623–1625页。[47] T. N. Kipf和M. Welling，“基于图卷积网络的半监督分类”，arXiv预印本arXiv:1609.02907，2016年。[48] H. Dong、J. Chen、F. Feng、X. He、S. Bi、Z. Ding和P. Cui，“关于解耦图卷积网络与标签传播的等价性”，载于《2021年万维网大会论文集》，2021年，第3651–3662页。[49] J. Wu、X. He、X. Wang、Q. Wang、W. Chen、J. Lian和X. Xie，“面向上下文感知推荐系统的图卷积机”，《计算机科学前沿》，第16卷，第6期，第166614页，2022年。[50] H. Chen、Y. Bei、Q. Shen、Y. Xu、S. Zhou、W. Huang、F. Huang、S. Wang和X. Huang，“面向在线十亿级推荐系统的宏观图神经网络”，载于《ACM 2024年万维网大会论文集》，2024年，第3598–3608页。[51] W. Yu和Z. Qin，“基于低通协同滤波器的推荐图卷积网络”，载于《国际机器学习会议》。PMLR，2020年，第10 936–10 945页。[52] H. Zhou、H. Chen、J. Dong、D. Zha、C. Zhou和X. Huang，“用于图协同过滤的自适应流行度去偏聚合器”，载于《第46届国际ACM SIGIR信息检索研究与发展会议论文集》，2023年，第7–17页。[53] J. Wu、X. Wang、F. Feng、X. He、L. Chen、J. Lian和X. Xie，“用于推荐的自监督图学习”，载于《第44届国际ACM SIGIR信息检索研究与发展会议论文集》，2021年，第726–735页。[54] X. He和T.-S. Chua，“用于稀疏预测分析的神经因子分解机”，载于《第40届国际ACM SIGIR信息检索研究与发展会议论文集》，2017年，第355–364页。