arXiv:2303.00243v1 [cs.IR] 1 Mar 2023

GUESR：采用桶聚类采样进行全局无监督数据增强的序列推荐

Yongqiang Han[1],Likang Wu[1], Hao Wang*[1]、Guifeng Wang[2], Mengdi Zhang[3],Zhi Li[1], Defu Lian[1], 和Enhong Chen[1]

[1] 中国科学技术大学安徽省大数据分析与应用重点实验室，中国合肥{harley,wulk,wanghao3,zhili03}@mail.ustc.edu.cn，{liandefu@，cheneh}@ustc.edu.cn[2] 华为技术有限公司，中国杭州 wangguifeng4@huawei.com[3] 美团点评集团，中国北京 zhangmengdi02@meituan.com

摘要。 序列推荐是一种广泛研究的范式，旨在从用户的历史交互中学习其动态兴趣，以预测下一个潜在物品。尽管大量研究取得了显著进展，但仍受困于一些常见问题：监督信号有限导致的数据稀疏性，以及意外点击造成的数据噪声。为此，一些研究尝试解决这些问题，却忽略了不同序列中物品之间复杂的关联。为沿着这一方向缓解困境，并学习具有代表性的物品嵌入，我们从图对比学习的视角提出了GUESR。具体而言，我们首先根据所有交互序列构建全局物品关系图（GIRG），并提出桶聚类采样（BCS）方法来生成子图。然后，在这一精简后的图上开展图对比学习，从全局视角利用复杂关联增强物品表示。随后，我们扩展CapsNet模块，并精心引入目标注意力机制，以推导用户的动态偏好。大量实验结果表明，我们提出的GUESR不仅能够取得显著提升，还可作为一种通用增强策略，与其他序列推荐方法结合以提升性能。

关键词： 序列推荐 · 图神经网络 · 对比学习

1 引言

随着互联网的快速发展，推荐系统已广泛应用于在线平台。其中，序列推荐（SR）将历史交互视为按时间排序的序列，以此预测用户的下一个物品，吸引了学术界和工业界的广泛关注。近年来，大量相关研究相继提出并取得了显著进展。最初的方法通常

基于神经网络 [7,12]。考虑到交互过的物品对下一步预测的重要性各不相同，研究人员进一步引入注意力机制，以量化序列中各物品的权重，例如 SASRec [8] 和 BERT4Rec [11]。一些研究探索了图神经网络在序列推荐中的应用，并捕捉交互序列中隐含的复杂物品模式，例如 SR-GNN [1] 和 GC-SAN [19]。然而，这些方法大多仍面临数据稀疏性和噪声问题，因此容易因训练信号有限以及物品之间的关联复杂而失效。与此同时，对比学习技术在表示学习领域取得了重大突破。受其成功的启发，一些方法将对比学习应用于提升序列推荐效果，例如 S^3Rec [22] 和 CL4SRec [18]。

尽管这些方法通常取得了显著成效，但仍存在一些可以改进的不足。首先，大多数序列方法分别利用每个序列中物品的局部上下文，其中物品间的共现信息容易受到噪声影响，而跨多个序列的关联也未能得到充分捕捉。其次，物品的流行度近似呈长尾分布，许多物品的交互数据十分稀疏。在某些情况下，现有模型对这些物品的表示可能会引入选择偏差。第三，尽管近期一些研究已应用对比学习来缓解交互数据的稀疏性，但它们通常随机构造数据增强，且未充分考虑如何针对序列推荐任务的特点设计合适的对比学习策略。

为此，本文将图对比学习引入序列推荐，以学习信息丰富的物品表示，并为准确刻画用户兴趣奠定坚实基础。具体而言，我们提出了一种新颖的框架 GUESR，即**全**球**无**监督的**数**据增强**序**列**推**荐方法。具体来说，我们首先根据所有交互序列构建全局物品关系图（GIRG）。我们将物品不同顺序的邻接信息量化为边权重，以获取物品间的复杂关联，并设置阈值来滤除噪声。在这种设置下，流行度较高的物品会移除更多边，从而降低物品流行度偏差。随后，我们采用图对比学习来学习这些全局关联信息，进而学习增强后的物品表示。此外，我们提出桶聚类采样（BCS）方法，以缓解不恰当负样本带来的采样偏差并使表示空间分布均匀，同时兼顾效率与效果。此外，我们进一步扩展 CapsNet [10]，加入目标注意力机制，以推导用户对多重兴趣的偏好，并将其构建为预测函数。最后，我们联合优化该范式的损失与所提出的辅助对比学习任务。总而言之，本文的贡献如下：

– 我们提出了一种用于序列推荐的全局对比数据增强框架，称为 GUESR。该框架在构建的全局图上采用图对比学习，以捕捉跨序列物品之间的复杂关联，从而缓解数据稀疏性和噪声问题。

为减轻不恰当的负样本的影响，我们提出了桶聚类采样（BCS）方法，并结合属性知识，从效率和有效性两方面获益。– 在公开可用数据集上的大量实验表明，GUESR 的性能优于最先进的方法。此外，进一步的分析验证了 GUESR 是一个通用模块，能够提升其他序列推荐方法的性能。

2 相关工作

2.1 序列推荐

序列推荐（SR）旨在根据历史交互序列预测下一个物品。随着深度学习的发展，已有研究提出了多种基于神经网络的模型 [7,12]。此外，注意力机制是应用于序列推荐的强大工具，例如 SASRec [8] 和 BERT4Rec [11]。近年来，图神经网络在处理图结构数据方面取得了最先进的性能[13,14,17,16]。由于强大的图神经网络能够捕获用户序列中隐藏的复杂物品转移模式，因此已有一些研究将图神经网络应用于 SR，例如 SR-GNN [1]和 GC-SAN [19]。然而，上述大多数方法都是通过预测损失进行训练，以优化整个序列的表示来提升推荐性能，却忽略了有价值的无监督信号。

2.2 用于推荐的对比学习

对比学习是一种新兴的无监督学习范式，已成功应用于计算机视觉和自然语言处理领域。同时，一些模型正将对比学习技术应用于序列推荐场景 [22,18,4,15], S^3Rec [22] 通过互信息最大化，为数据表示学习设计了四种辅助自监督目标。CL4SRec [18] 采用三种数据增强方法生成正样本对，并通过对比正样本对来学习稳健的序列转移模式。尽管取得了这些成果，基于对比学习的 SR 方法仍主要侧重于从每个序列中学习自监督信号。由于单个序列中的信息有限，所获得的自监督信号过于薄弱，无法编码出信息丰富的嵌入。

3 初步工作

考虑一组用户 $U(|U| = M)$ 和物品 $V(|V| = N)$，每位用户$u \in U$ 都有一个按时间顺序排列的交互物品序列 $I_u = [I_1^u, \ldots, I_t^u, \ldots, I_m^u]$，其中 m 是交互物品的预定义最大容量，I_t^u是用户在步骤 t交互的物品。给定一个观测序列 I_u，序列推荐的典型任务是预测用户 u 最有可能交互的下一个物品 I_{m+1}^u。

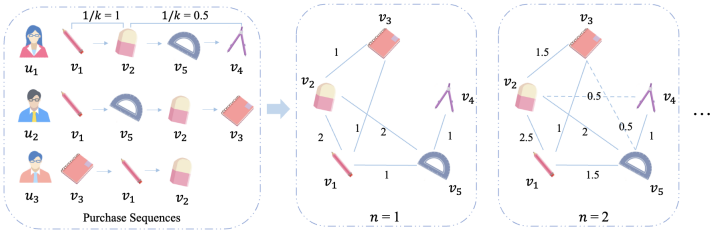

图 1. 示例展示了如何从物品序列中构建 GIRG。

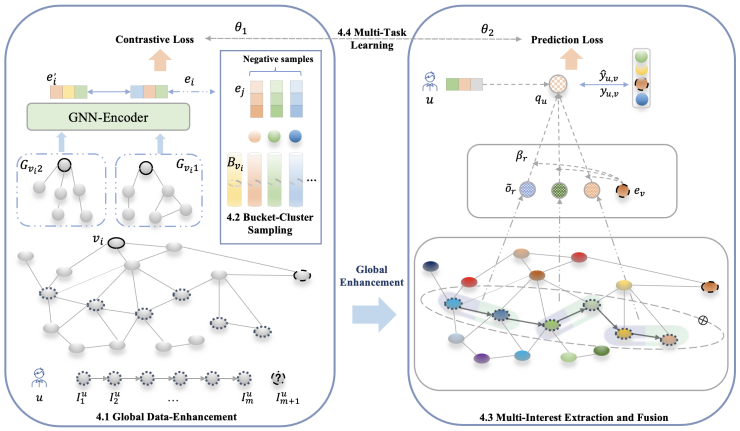

图 2. 我们提出的 GUESR 的网络架构。

不同于现有方法 [7,8,22,18] 分别利用每个序列中物品的局部上下文，我们首先根据所有交互序列生成一个全局物品关系图（GIRG） G ，其中每个物品都通过无向边相连。值得一提的是，我们不会合并序列中的重复物品。边权重取决于序列中各物品的相邻关系。具体而言，我们定义一个 n-GIRG，其中两条边的权重为所有序列中 $k_{th}(k = [1, 2, \cdots, n])$直接连接数量之和，且 k 表示物品的相邻间隔。这一经验设置受到先前工作的启发 [6]。对于 (v_i, v_j)，我们计算 w_{ij} ，然后对边权重进行归一化，以得到 w'_{ij}。上述过程如下：

$$w_{ij} = \sum_{u \in U} \sum_{k=1}^{n} \frac{\delta(|loc(v_i) - loc(v_j)| = k \mid v_i, v_j \in I_u)}{k}, w'_{ij} = Norm(w_{ij}). \quad (1)$$

其中， $loc(\cdot)$表示物品 $v_i \in S_u$的位置， δ 表示序列中两个物品的位置相差 k 的次数， $deg(\cdot)$表示 G中节点的度。之后，我们设置一个超参数阈值 ε ，删除部分边 [2] 以减少噪声，并得到最终边权重$\hat{w}_{ij}$。也就是说，这缓解了物品的流行度偏差，因为流行度高的物品会有更多边被删除。

4 方法

4.1 全局数据增强

众所周知，图对比学习方法高度依赖于增强方案 [9]的选择。基于对以往工作的探索，我们采用了一种适用于全局图场景的基于概率的数据增强方法。根据前述步骤，我们利用超参数 ε 和 n，为所有序列构建GIRG G 。之后，对于特定物品 v_i，我们按照概率 p_{ij}在 G中采样其邻居 v_j ，该概率为边权重ˆw_{ij} 与采样深度 D之比。请注意，采样过程是迭代进行的：收集到一个节点后，其相邻节点将被加入采样池。通过这种方式，可以保留目标节点的语义信息。经过两次采样，我们为特定物品 v_i获得两个增强视图 G_{v_i1} 和 G_{v_i2} 。随后，将 LightGCN [6] 方法用作编码器，并在不同视图中共享参数。以获得的视图 G_{v_i1} 为例，物品 v_i 在第 l层的信息传播与聚合如下：

$$e_i^{(l+1)} = \sum_{v_j \in N_i} \frac{e_j^{(l)}}{\sqrt{deg(v_i)}\sqrt{deg(v_j)}}, \qquad e_i = \sum_{l=0}^{L} \alpha_l e_i^{(l)}, \tag{2}$$

其中，$^{(l)}e_i$ 表示 l层中 v_i 的表示。 N_i 表示 G_{v_i1} 中 v_i的邻居集合， α_l 表示 l层中用于最终嵌入的权重，该权重作为模型参数进行训练。在 G_{v_i1}上进行 L 层信息传播后，我们将 v_i 的嵌入表示为 e_i。类似地，另一视图 G_{v_i2} 中的 v_i 的嵌入表示为 e'_i。

4.2 桶聚类采样

以往工作 [18,22]大多采用批内负样本，或从训练数据中随机采样。这种方式可能导致采样偏差，损害表示空间的均匀性。为了解决这一问题，我们提出桶聚类采样（BCS）方法，以减轻这些不恰当的负样本带来的影响。

一般而言，我们根据初始属性和当前嵌入迭代地划分桶。首先，我们使用数据集中提供的粗粒度属性信息作为划分桶的依据，以确定物品 v_i 最初所属的桶。根据 K均值算法，将 K 个桶（μ_1，μ_2，.....，μ_K）的中心计算为各桶中物品嵌入的均值。然后，我们计算每个物品嵌入 e_i与聚类中心 μ_j之间的距离。最后，我们将物品 v_i 分配到桶 B_{v_i} ，并根据桶的大小，从其他桶中均匀抽取 N_{neg} 个负样本。尽管该算法相对简单，但实验表明，由于引入了先验知识，这种采样方法是有效的。整个过程可表示为：

$$B_{v_i} = \arg\max_b \left[(1-\lambda) * \mathbf{I}(v_i \in B_{v_i}^{orig}) + \lambda * \frac{\|e_i - \mu_b\|^2}{\sum_{k=1}^{K} \|e_i - \mu_k\|^2}\right], \tag{3}$$

这里**I(·)**表示 v_i 是否原本就在桶 $B_{v_i}^{orig}$中，超参数 λ 用于控制先验知识的权重。

4.3 多兴趣提取与融合

在这一部分，我们利用 CapsNet [10] 生成用户的多重兴趣，然后采用目标注意力机制推导用户偏好。具体而言，为了在序列推荐中利用关键的时间信息，我们使用 Transformer 对交互序列进行编码，并在对 S 进行线性投影（参数为 $W^z \in \mathbb{R}^{d\times d}$）后，额外引入残差操作，从而获得序列模式 $Z \in \mathbb{R}^{m\times d}$ 。

然后，我们将$\mathbf{g} = [g_1, g_2, \cdots, g_m]$定义为一致性评分，用于表示每个物品与胶囊的相关性。假设我们有 R 个兴趣胶囊，对于第 r个胶囊，其隐藏表示 $h_r \in \mathbb{R}^d$ 通过一致性评分和softmax函数对每个序列模式 $z_i \in Z$ 进行汇总。然后，第 r个胶囊的输出记为 $o_r \in \mathbb{R}^d$ ，由非线性压缩函数得到。紧接着，根据输出和序列模式嵌入更新一致性评分 g_i 。上述过程可以表示如下:

$$h_r = \sum_{i=1}^{m} softmax(g_i) z_i, \qquad o_r = \frac{\|h_r\|^2}{1+\|h_r\|^2}\frac{h_r}{\|h_r\|}, \qquad g_i = g_i + o_r^\top z_i. \tag{4}$$

对于每个兴趣胶囊，我们将上述过程迭代 T 次。最终一次迭代的输出输入全连接层和ReLU激活函数，以得到兴趣表示:

$$\tilde{o}_r = ReLU\left(o_r {W_r}^o\right). \tag{5}$$

兴趣的权重受目标物品 [21]影响。例如，体育爱好者可能会点击推荐的自行车，即使此前已经点击过几本图书。通过上述过程，我们得到兴趣表示 $[\tilde{o}_1, \tilde{o}_2 \cdots \tilde{o}_R]$，其中 R是兴趣胶囊的数量。给定嵌入为 e_v的目标物品，我们利用目标注意力机制来得到用户偏好，具体过程如下:

$$\beta_r = \frac{\exp\left(\tilde{o}_r^\top e_v\right)}{\sum_{j=1}^{R}\exp\left(\tilde{o}_j^\top e_v\right)}, \qquad q_u = \sum_{r=1}^{R}\beta_r \tilde{o}_r + u. \tag{6}$$

其中， β_j 是注意力权重， q_u 是整合兴趣的表示。加入用户向量 u 以保持用户的独特性，并通过内积$\hat{y}_{u,\ v} = q_u e_v$计算推荐分数。

4.4 多任务学习

在主要预测任务和对比学习任务中，我们在本节对二者进行联合优化。具体而言，我们使用 InfoNCE损失 [3]来区分同一项目的增强表示与其他项目的表示。此外，我们采用二元交叉熵（BCE）损失来完成预测任务。

$$\mathcal{L}_{CL} = -\sum_{v_i \in V}\left[\log\frac{\exp\left(\mathbf{sim}\left(e_i, e_i'\right)/\tau\right)}{\sum_{j=1}^{N_{neg}}\exp\left(\mathbf{sim}\left(e_i, e_j\right)/\tau\right)}\right], \tag{7}$$

$$\mathcal{L}_{Pred} = -\sum_{u,v} \left[y_{u,v} \ln \left(\hat{y}_{u,v} \right) + \left(1 - y_{u,v} \right) \ln \left(1 - \hat{y}_{u,v} \right) \right]. \tag{8}$$

因此，GUESR 的最终目标函数为：

$$\mathcal{L}_{Total} = \theta_1 \mathcal{L}_{Pred} + \theta_2 \mathcal{L}_{CL} + \theta_3 \|\Theta\|_2, \tag{9}$$

其中， θ_3 是用于防止过拟合的 $L2$ 正则化参数。

5 实验

5.1 实验设置

数据集。 我们在四个公开可用、属于不同领域 [5]的数据集上进行了实验。数据集的详细统计信息见表 1。

表 1。数据集的统计信息。

数据集	# 用户	# 物品	# 交互	稀疏度
ML-1M	6,040	3,618	836,434	96.18%
体育	35,598	18,357	296,337	99.95%
Yelp	45,478	30,709	1,777,765	99.87%
图书	58,145	58,052	2,517,437	99.93%

实现细节。 为开展实验，对于每位用户，我们将交互序列的前 80% 作为训练数据，接下来的 10% 作为验证数据，剩余的 10% 作为测试数据。所有基线方法均在相关工作中进行了介绍。为确保比较公平，我们保持实验环境一致，并仔细搜索超参数。为避免候选项选择带来的采样偏差问题 [20], ，我们采用全排序策略。为与最先进的对比基线方法比较性能，我们采用两种广泛使用的评估指标：Recall@K 和 NDCG@K，并将 K 设为 10 和 20。

5.2 性能比较

本节通过对四个公开数据集上的召回率和 NDCG 指标进行排序，报告总体推荐性能，如表2所示，并总结以下观察结果。

首先，我们可以得出结论：SR-GNN 和 GC-SAN 的表现通常优于 BPR MF、GRU4Rec 和 Caser，这进一步印证了先前研究的结论，即它们能够表示用户和物品的更多高阶信息。其次，我们注意到，引入自注意力机制的 SASRec，其表现优于 GRU4Rec 和 Caser，这表明自注意力架构适用于序列建模，并能更好地捕捉序列中物品的长期依赖关系。第三，对于自监督学习方法，我们发现 CL4Rec 和 S^3Rec 的表现始终优于采用单一范式损失的其他基线方法，这证明了将自监督任务引入序列推荐问题的有效性。最后但同样重要的是，我们观察到，在所有数据集上，所提出的 GUESR 在两项评估指标上的表现始终优于所有基线方法，这表明我们提出的全局增强图对比学习具有优势。

表2。 不同模型的性能。本文将最佳结果用粗体标出，次佳结果用符号'*'标记。

数据集	指标	BPRMF	GRU4Rec	Caser	SASRec	LightGCN	SR-GNN	GC-SAN	S^3Rec	CL4Rec	GUESR
ML-1M	R@10	0.1812	0.1843	0.1756	0.1932	0.1836	0.1885	0.1940	0.1995	0.2034*	**0.2157**
	N@10	0.2455	0.2465	0.2387	0.2605	0.2463	0.2507	0.2572	0.2638	0.2701*	**0.2879**
	R@20	0.2712	0.2734	0.2643	0.2895	0.2729	0.2762	0.2850	0.2940	0.3001*	**0.3147**
	N@20	0.2558	0.2567	0.2434	0.2730	0.2565	0.2625	0.2707	0.2790	0.2823*	**0.2951**
体育	R@10	0.1032	0.1043	0.1021	0.1145	0.1040	0.1132	0.1176	0.1221	0.1231*	**0.1342**
	N@10	0.0854	0.0893	0.0833	0.0993	0.0885	0.0935	0.0988	0.1041	0.1054*	**0.1118**
	R@20	0.1284	0.1302	0.1139	0.1402	0.1298	0.1335	0.1385	0.1438	0.1492*	**0.1579**
	N@20	0.0987	0.0992	0.0921	0.1093	0.0991	0.1015	0.1069	0.1123	0.1143*	**0.1239**
Yelp	R@10	0.0635	0.0643	0.0634	0.0798	0.0647	0.0732	0.0808	0.0884	0.0892*	**0.0981**
	N@10	0.0452	0.0487	0.0435	0.0601	0.0480	0.0539	0.0610	0.0682*	0.0678	**0.0753**
	R@20	0.1038	0.1046	0.1042	0.1203	0.1044	0.1236	0.1291	0.1346	0.1362*	**0.1457**
	N@20	0.0572	0.0598	0.0578	0.0710	0.0602	0.0643	0.0728	0.0798	0.0812*	**0.0862**
图书	R@10	0.0621	0.0683	0.0624	0.0829	0.0725	0.0763	0.0847	0.0931*	0.0921	**0.1032**
	N@10	0.0431	0.0462	0.0445	0.0583	0.0501	0.0506	0.0587	0.0674*	0.0672	**0.0735**
	R@20	0.0972	0.1032	0.1001	0.1249	0.1056	0.1116	0.1205	0.1295	0.1307*	**0.1401**
	N@20	0.0529	0.0542	0.0546	0.0700	0.0569	0.0609	0.0694	0.0780	0.0795*	**0.0849**

表3. GUESR各个模块取得的性能。

数据集	指标	GUESR	GUESR-GCL	GUESR-W	GUESR-BCS	CL4Rec
ML-1M	R@20	**0.3147**	0.2802（-11.0%）	0.3087（-1.9%）	0.2954（-6.1%）	0.3001*
	N@20	**0.2951**	0.2625（-11.0%）	0.2886（-2.2%）	0.2799（-5.1%）	0.2823*
图书	R@20	**0.1401**	0.1149 (-18.0%)	0.1332 (-5.0%)	0.1282 (-8.5%)	0.1307*
	N@20	**0.0849**	0.0602（-29.1%）	0.0821（-3.3%）	0.0723（-14.8%）	0.0795*

5.3 消融研究

本节将通过消融研究验证并量化所提出的 GUESR 中各个组件的有效性。具体而言，我们设置了以下对比方案：1). GUESR-GCL：表示移除图对比学习损失；2). GUESR-W：表示在构建全局物品图时不考虑边权重，并将n=1 设为n （物品的最大相邻间隔。）；3). GUESR-BCS：表示使用随机负采样代替桶-簇采样。对比结果如表3所示。

从表3所示的结果中，我们可以得出以下结论：首先，与原始模型相比，GUESR-GCL 在两项评估指标上的性能均大幅下降，这证明了采用对比学习来缓解序列推荐中的数据稀疏性和噪声问题是有效的。其次，通过与 GUESR-W 进行比较，我们可以证明，所构建的全局物品关系图（GIRG）在捕捉物品间的复杂关联方面发挥着重要作用。第三，通过与 GUESR-BCS 进行比较，我们可以得出结论：桶聚类采样（BCS）方法通过引入属性知识，不仅能够减轻不恰当的负样本带来的影响，还能提高效率，并进一步提升所提出的 GUESR 的有效性。

5.4 增强模块的影响

在本部分中，我们将探讨 GUESR 中提出的增强模块能否作为一种通用框架，并灵活地与其他序列推荐范式相结合。在这里，我们考虑 GRU4Rec、Caser 和 SASRec，并为它们分别加入增强模块，这些模型

通过对比学习损失和预测损失进行联合优化。从表中可以看出，所有增强模型的表现始终优于相应的骨干模型，这表明 GUESR 提出的全局图对比学习增强策略可以作为一种通用模块，直接应用于许多现有的序列推荐范式。

表4。 采用所提出的增强模块进行性能比较。

数据集	指标	GRU4Rec	EGRU4Rec	Caser	ECaser	SASRec	ESASRec
ML-1M	R@20	0.2734	0.2809(+2.7%)	0.2643	0.2760 (+4.4%)	0.2895	0.2941(+1.6%)
	N@20	0.2567	0.2635(+2.7%)	0.2434	0.2602 (+7.0%)	0.2730	0.2798(+2.5%)
体育	R@20	0.1302	0.1354(+4.0%)	0.1139	0.1332(+17.0%)	0.1402	0.1435(+2.4%)
	N@20	0.0992	0.1055(+6.4%)	0.0921	0.1021(+10.9%)	0.1093	0.1117(+2.2%)

6 结论

在这项工作中，我们针对序列推荐问题提出了一种新颖的图对比学习范式，称为 GUESR，旨在显式捕捉物品在局部和全局上下文中的潜在相关性。在四个公开数据集上进行的大量实验表明，我们提出的 GUESR 不仅能够取得显著提升，还可视为一种通用增强策略，与其他序列推荐方法结合时能够进一步提升性能。

7 致谢

本研究得到国家自然科学基金项目（编号：62202443）的资助，同时也得到美团集团的支持。

参考文献

1. Bera, A., Wharton, Z., Liu, Y., Bessis, N., Behera, A.: Sr-gnn：用于细粒度图像分类的空间关系感知图神经网络。IEEE图像处理汇刊 **31**, 6017–6031 (2022) 2. Chang, J., Gao, C., Zheng, Y., Hui, Y., Niu, Y., Song, Y., Jin, D., Li, Y.: 基于图神经网络的序列推荐。载于：第44届国际ACM SIGIR信息检索研究与发展会议论文集。第378–387页 (2021) 3. Chen, T., Kornblith, S., Norouzi, M., Hinton, G.: 视觉表征对比学习的简单框架。载于：国际机器学习会议。第1597–1607页。PMLR (2020) 4. Chen, Y., Liu, Z., Li, J., McAuley, J., Xiong, C.: 用于序列推荐的意图对比学习。载于：ACM Web会议。第2172–2182页 (2022) 5. Haque, T.U., Saber, N.N., Shah, F.M.: 大规模亚马逊产品评论的情感分析。载于：2018年IEEE创新研究与发展国际会议（ICIRD）。第1–6页。IEEE (2018) 6. He, X., Deng, K., Wang, X., Li, Y., Zhang, Y., Wang, M.: 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。第639–648页 (2020)

7. Hidasi, B., Karatzoglou, A., Baltrunas, L., Tikk, D.: 使用循环神经网络的基于会话的推荐。arXiv预印本 arXiv:1511.06939 (2015) 8. Kang, W.C., McAuley, J.: 自注意力序列推荐。载于：2018年IEEE国际数据挖掘会议（ICDM）。第197–206页。IEEE (2018) 9. Lee, N., Lee, J., Park, C.: 图上的无增强自监督学习。载于：AAAI人工智能会议。第7372–7380页。第7期 (2022) 10. Sabour, S., Frosst, N., Hinton, G.E.: 胶囊间的动态路由。神经信息处理系统进展 **30** (2017) 11. Sun, F., Liu, J., Wu, J., Pei, C., Lin, X., Ou, W., Jiang, P.: BERT4Rec：利用来自Transformer的双向编码器表示进行序列推荐。载于：第28届ACM国际信息与知识管理会议论文集。第1441–1450页 (2019) 12. Tang, J., Wang, K.: 通过卷积序列嵌入实现个性化Top-N序列推荐。载于：第十一届ACM国际网络搜索与数据挖掘会议论文集。第565–573页 (2018) 13. Wang, H., Lian, D., Tong, H., Liu, Q., Huang, Z., Chen, E.: 属性网络的解耦表征学习。IEEE知识与数据工程汇刊 (2021) 14. Wang, H., Xu, T., Liu, Q., Lian, D., Chen, E., Du, D., Wu, H., Su, W.: MCNE：社交网络多种条件网络表征学习的端到端框架。载于：第25届ACM SIGKDD国际知识发现与数据挖掘会议论文集。第1064–1072页 (2019) 15. Wei, Y., Wang, X., Li, Q., Nie, L., Li, Y., Li, X., Chua, T.S.: 面向冷启动推荐的对比学习。载于：第29届ACM国际多媒体会议论文集。第5382–5390页 (2021) 16. Wu, L., Li, Z., Zhao, H., Pan, Z., Liu, Q., Chen, E.: 通过基于图的市场环境模型估计创新项目的早期融资表现。载于：AAAI人工智能会议论文集。第34卷，第6396–6403页 (2020) 17. Wu, L., Wang, H., Chen, E., Li, Z., Zhao, H., Ma, J.: 面向网络感知级联预测的偏好增强型社交影响建模。载于：第45届国际ACM SIGIR信息检索研究与发展会议论文集。第2704–2708页 (2022) 18. Xie, X., Sun, F., Liu, Z., Wu, S., Gao, J., Zhang, J., Ding, B., Cui, B.: 用于序列推荐的对比学习。载于：2022年IEEE第38届国际数据工程会议（ICDE）。第1259–1273页。IEEE (2022) 19. Xu, C., Zhao, P., Liu, Y., Sheng, V.S., Xu, J., Zhuang, F., Fang, J., Zhou, X.: 用于基于会话推荐的图上下文自注意力网络。载于：IJCAI。第19卷，第3940–3946页 (2019) 20. Zhao, W.X., Chen, J., Wang, P., Gu, Q., Wen, J.R.: 重新审视评估Top-N物品推荐算法的替代实验设置。载于：第29届ACM国际信息与知识管理会议论文集。第2329–2332页 (2020) 21. Zheng, Y., Gao, C., Chang, J., Niu, Y., Song, Y., Jin, D., Li, Y.: 解耦推荐中的长短期兴趣。载于：2022年ACM Web会议论文集。第2256–2267页 (2022) 22. Zhou, K., Wang, H., Zhao, W.X., Zhu, Y., Wang, S., Zhang, F., Wang, Z., Wen, J.R.: S3-Rec：通过互信息最大化进行序列推荐的自监督学习。载于：第29届ACM国际信息与知识管理会议论文集。第1893–1902页 (2020)