

张恒, 谢程远, 程宇, 等. 基于多视图增强的跨层交叉对比学习推荐方法[J]. 智能计算机与应用, 2025, 15(10): 89-95.
DOI:10.20169/j.issn.2095-2163.251013

基于多视图增强的跨层交叉对比学习推荐方法

张恒, 谢程远, 程宇, 龚文正

(安徽建筑大学 电子与信息工程学院, 合肥 230601)

摘要: 现有的基于图卷积神经网络(GCN)的序列推荐模型存在一定缺陷,主要表现在对不同层的感知不均衡。针对上述问题,提出一种基于多视图增强的跨层次对比学习推荐框方法(Multi-view Augmentation based Cross-layer Cross-comparison Learning recommendation method, MACCL)。该框架构造了用户项目交互图、用户图和项目图三个视图,在图上采用2种不同的视图增强方法,避免单个增强方法造成负面影响。在用户项目图上使用随机添加噪音的方法进行增强,对于用户图和项目图新增一种视图增强方法,通过添加关系注意力机制增强邻域实体的节点表示。然后,分别将2个视图的不同层的嵌入表示进行跨层交叉对比,以获取更多的均衡特征。最后,联合优化模型,以此提升推荐性能。在Tmall、Amazon-book两个公开数据集上进行了大量的实验,实验结果表明MACCL的有效性和可行性。

关键词: 序列推荐; 视图增强; 对比学习; 多视图

中图分类号: TP181

文献标志码: A

文章编号: 2095-2163(2025)10-0089-07

Multi-view augmentation based Cross-layer Cross-comparison Learning recommendation method

ZHANG Heng, XIE Chengyuan, CHENG Yu, GONG Wenzheng

(School of Electronics and Information Engineering, Anhui Jianzhu University, Hefei 230601, China)

Abstract: Existing sequential recommendation models based on Graph Convolutional Neural network (GCN) have certain shortcoming, witch is the perception of different layers is not balanced. Based on the above problem, a Multi-view Augmentation based Cross-layer Cross-comparison Learning recommendation framework method MACCL is proposed. The research constructs a user project interaction diagram, user diagram and project diagram, using two different view augmentation methods on the diagrams to avoid the negative impact of a single augmentation method. The user-item graph is enhanced using the method of randomly adding noise, and a new view enhancement method is added for the user and project graphs to enhance the node representation of neighbourhood entities by adding the relational attention mechanism. Subsequently, the embedded representations of different layers of the two views are cross-referenced across layers separately to obtain more balanced features. Finally, the models are jointly optimised as a way to improve recommendation performance. Extensive experiments are conducted on two public datasets, namely Tmall and Amazon-book, and the experimental results demonstrate the effectiveness and feasibility of MACCL.

Key words: sequence recommendation; view augmentation; contrastive learning; multi-view

0 引言

序列推荐^[1-4](SR)技术引起了越来越多的关注。与传统的包括协同过滤和基于内容的过滤的推荐系统^[5]不同,序列推荐试图理解和建模顺序用户行为、用户和物品之间的交互,以及用户偏好和物品流行度随时间的演变,然后从海量的数据中为用户推荐感兴趣的物品。随着对比学习^[6-7]的快速发

展,图卷积神经网络^[8-9]在序列推荐中的性能得到了提升,但是仍存在一些挑战:

(1) 现有模型对结构信息的利用不够充分,从内向外的传播方式会使得特征信息在传播过程中逐渐减弱,使得聚合后的特征信息过于复杂,导致推荐不准确。

(2) 现有的对比学习只对比同一节点的一对视图,并没有很好地利用各视图不同的层嵌入,且鲜有

研究尝试改进对比学习,限制了模型的性能提升。

为了解决上述问题,本文提出了一种基于多视图增强的跨层交叉对比学习推荐算法框架。本文构建了3种图,即用户项目交互图、用户图和项目图。其中,用户图和用户项目交互图从不同的角度提供用户的信息,项目图和用户项目交互图中则有能助益建模项目的信息。此外,引入了一种新的视图增强方法,通过考虑关系对实体的影响,来增强邻域信息。然后使用提出的多视图跨层交叉对比学习,利用视图最内层和最外层的节点表示进行跨层次对比学习,以缓解不同层的信息利用不均衡问题,从而获得高质量的节点表示,提高推荐性能。

1 相关工作

与传统推荐算法相比,序列推荐算法考虑了交互序列中物品的顺序。早期研究基于序列的推荐方法主要基于马尔科夫链,马尔科夫方法可以对用户的交互序列进行建模,根据转移概率预测下一个可能与用户产生交互的物品。FPMC^[10]算法通过结合一阶马尔可夫链来对序列行为和长期用户偏好进行建模。FPMC-LC^[11]算法改进了FPMC算法的转移矩阵。但是都只能捕获交互序列的局部信息^[12]。

随着深度学习技术的研发与应用,已有研究指出循环神经网络^[13](RNN)可以解决以马尔科夫链为基础的算法存在的缺陷。GRU4Rec^[14]是以RNN为基础的推荐算法,并且结合了门控单元(GRU),通过采用多层门控递归单元(GRU)来对项目之间的顺序转换关系进行建模。LSTM^[15]则主要是用来处理具有时间序列的数据任务,比如文本翻译、文本转语音等。

图神经网络技术(GNN)逐渐成熟,Wu等学者首次将交互序列构造为图结构数据,提出SR-GNN^[16]模型,利用GNN对物品间高阶转换关系进行建模,缺点是只关注当前会话中项目之间的转换关系,没有考虑全局信息。在此基础上,Wang等学者^[17]提出GCE-GNN,构建了会话图和全局图,并分别从不同的级别学习项目的表示。文献^[18]提出FGNN模型,利用加权注意网络学习会话序列中物品间隐藏信息。NGCF^[19]通过聚合交互项目(或用户)的嵌入来细化用户(或项目)的嵌入。通过堆叠多个嵌入传播层,可以强制嵌入以捕获高阶连接中的协作信号。

最近,一些研究提出将对比学习引入推荐系统。SGL^[20]将节点自识别作为自监督任务,为现有的基

于GCN的推荐模型提供了辅助信号。CL4SRec^[17]利用传统next-item prediction与对比学习框架从用户原始行为序列生成自监督信息,以提取更多的用户行为并进行编码,另外还采用了3种数据增强方式构建自监督信息。DuoRec^[22]利用对比学习来重建序列的表征,一方面,利用基于Dropout的方式在模型层面对序列表征进行增强;另一方面,利用相似序列挖掘正样本和负样本,结合对比学习进行约束。

虽然上述方法在推荐任务上取得了不错的效果,但视图增强方法单一且只考虑对比一对视图的同一节点。因此在本文中,融合用户和项目之间的关系信息,来进行视图增强,同时利用好各视图不同的层嵌入进行对比学习。

2 方法

2.1 方法基本思想

本节将从4个部分详细描述提出的推荐框架MACCL(框架模型具体如图1所示):图编码层、视图增强、跨层交叉对比学习和联合训练。

(1)图编码层:使用轻量化图卷积神经网络,挖掘特征信息。

(2)视图增强:使用随机添加噪声和添加关系信息。

(3)跨层交叉对比学习:使用对比学习(CL)辅助损失函数分别从用户和项目所在的3个视图的不同层嵌入进行交叉对比。

(4)预测层:使用用户和项目的最终表示向量的内积来预测用户对该项目的偏好得分。

2.2 问题阐述

序列推荐模型的任务是预测用户最有可能与之交互的下一个项目。用 $V = \{v_1, v_2, \dots, v_M\}$ 表示所有物品集合, $U = \{u_1, u_2, \dots, u_N\}$ 表示所有用户的集合, $S = \{v_1, v_2, \dots, v_t\}$ 表示交互序列, v_t 是用户 u 的第 t 个交互。

(1)用户项目交互图:通过用户和项目的历史交互构造一个图 $G_a = \{u, y_{uw}, v\}$, y_{uw} 表示用户和项目之间是否存在交互。如果用户 u 与项目 v 交互, $y_{uw} = 1$,否则 $y_{uw} = 0$ 。用户项目交互邻接矩阵为 $Y \in R^{M \times N}$ 。

(2)项目图:项目图定义为 $G_c = \{v_i, y_{v_i v_j}, v_j\}$,项目图邻接矩阵为 $Y_v \in R^{M \times M}$ 。

(3)用户图:用户图定义为 $G_b = \{u_i, y_{u_i u_j}, u_j\}$,用户图邻接矩阵为 $Y_u \in R^{N \times N}$ 。




图 1 MACCL 模型图

Fig. 1 MACCL model diagram

2.3 图编码层

由于 LightGCN^[23] 的有效性和轻量级架构, 通常选择使用 LightGCN 来聚合每个节点的邻域实体信息, 其在传播函数中摒弃了特征传播和激活函数, 加快了运行速度, 同时也保证了预测的精准度, 公式如下:

$$e_u^{(k)} = \sum_{i \in N_u} \frac{1}{\sqrt{|N_u| \cdot |N_i|}} e_i^{(k-1)} \quad (1)$$

$$e_i^{(k)} = \sum_{u \in N_i} \frac{1}{\sqrt{|N_u| \cdot |N_i|}} e_u^{(k-1)} \quad (2)$$

其中, $e_u^{(k)}, e_i^{(k)}$ 分别表示用户和项目在 k 层的嵌入表示; N_u, N_i 分别表示用户 u 和项目 i 的邻域集合; $1/\sqrt{|N_u| \cdot |N_i|}$ 表示对称归一项。然后将不同层次上的表示相加得到项目用户交互图最终的表示 z_{ui}, z_{vi} 。项目图和用户图同理得到:

$$z_{ui} = e_u^{(0)} + \dots + e_u^{(k)} \quad (3)$$

$$z_{vi} = e_i^{(0)} + \dots + e_i^{(k)} \quad (4)$$

2.4 视图增强

考虑到单个增强方法会造成负面影响, 所以使用 2 种视图增强方式, 即添加随机噪声和添加关系注意力来实现视图增强。

2.4.1 随机添加噪声

随机添加噪声, 即在第一层嵌入表示中引入服从均匀分布的噪声, 模拟特征的均匀分布, 实现数据增强。这种基于噪声的增强可以直接将嵌入空间正则化为更均匀的分布表示, 并通过调整噪声的大小, 平滑地调整表示的一致性。本文在聚集了一层邻居

的嵌入表示中随机添加一个噪声, 以获得增强的嵌入表示 x'_u, x'_i , 定义公式如下:

$$z'_{ui} = z_{ui} + \Delta_s \quad (5)$$

$$z'_{vi} = z_{vi} + \Delta_s \quad (6)$$

$$\Delta_s = p \times \|\varepsilon\|_2^2 \odot \text{sign}(z_{u,v}) \quad (7)$$

其中, $\varepsilon = R^d \sim U(0, 1)$, $\|\varepsilon\|_2^2$ 表示 $L2$ 正则化; “ \odot ” 表示 2 个向量的乘积; p 表示噪声比。通过改变噪声可以提供更均匀的特征。

2.4.2 添加关系信息

LightGCN 在交互视图方面建模方面有强大的建模功能, 但忽略了没有考虑关系的类型, 不同类型的关系也包含着重要信息, 这样会导致特征信息在传播过程中逐渐减弱。为了解决这一问题, 引入关系注意力机制以此来增强邻域信息。计算方法如下:

$$\alpha_{ij} = \frac{\exp(\text{LeakyReLU}(a_k^T [\mathbf{W}_b x_i \parallel \mathbf{W}_b x_j]))}{\sum_{k \in N_i} \exp(\text{LeakyReLU}(a_k^T [\mathbf{W}_b x_i \parallel \mathbf{W}_b x_k]))} \quad (8)$$

$$r_i = \text{ReLU}(\sum_{i, j \in U} \alpha_{ij} \cdot x_i \mathbf{W}_b) \quad (9)$$

$$r_j = \text{ReLU}(\sum_{i, j \in U} \alpha_{ij} \cdot x_j \mathbf{W}_b) \quad (10)$$

$$r_k = r_i + r_j \quad (11)$$

其中, x_i, x_j 表示用户的嵌入表示; N_i 表示节点 i 的邻居; r_k 为关系的嵌入表示; r_i, r_j 分别表示相邻 2 个节点作用下的关系表示; α_{ij} 表示不同用户的注意力系数; \mathbf{W}_b, a_k 表示可训练矩阵; “ \parallel ” 表示连接操作。最后将关系信息和用户信息拼接到一起, 公式如下:

$$\alpha'_{ij} = \frac{\exp(\text{LeakyReLU}(\mathbf{a}_b^T [\mathbf{W}_b \mathbf{x}_i \parallel \mathbf{W}_r \mathbf{r}_k \parallel \mathbf{W}_b \mathbf{x}_j]))}{\sum_{k \in N_i} \exp(\text{LeakyReLU}(\mathbf{a}_b^T [\mathbf{W}_b \mathbf{x}_i \parallel \mathbf{W}_r \mathbf{r}_k \parallel \mathbf{W}_b \mathbf{x}_k]))} \quad (12)$$

$$\mathbf{x}'_u = \text{ReLU}(\sum_{i \in u} \sum_{j \in u} \mathbf{x}_i \alpha'_{ij}) \quad (13)$$

$$\mathbf{x}_u^2 = [\mathbf{x}_u^1; \mathbf{x}'_u] \quad (14)$$

其中, \mathbf{x}_u^2 表示结合了关系信息的用户向量表示; \mathbf{x}_u^1 表示第一层的用户向量表示; $\mathbf{W}_b, \mathbf{W}_r, \mathbf{a}_b$ 表示可训练的矩阵; α'_{ij} 表示融合了关系信息的用户的注意力系数, 项目图同理。

2.5 跨层交叉对比学习

现有的对比学习方法, 只考虑到对比一对视图在同一层次下的同一节点, 但是忽略了随着信息不断的向外传播, 聚合的层数也在不断增加, 每一层都有各自的优点, 且和其余层有共享信息, 现有的方法没有充分利用这些信息, 导致层之间节点信息利用不均衡。所以提出了一种新的对比学习方法, 即多视图跨层交叉对比学习。

本方法中, 采用跨层交叉的目标是共享 2 个视图之间的信息, 将视图第一层或最外层中的节点与另外一个视图的第一层与最外层的相同节点作为正对进行对比。采用了基于 InfoNCE loss 的改进版本。

首先需要将 2 个视图映射到计算对比度损失的空间中, 然后将嵌入信息反馈到具有一个隐藏层的 MLP 中, 有以下对比损失:

$$L_c^u = \sum_{u \in U} -\log \frac{\exp(s(\mathbf{z}_u^1, \mathbf{z}_{ui}^1)/\tau)}{\sum_{ui' \in U} \exp(s(\mathbf{z}_u^1, \mathbf{z}_{ui'}^1)/\tau)} + \sum_{u \in U} -\log \frac{\exp(s(\mathbf{z}_u^1, \mathbf{z}_{ui}^2)/\tau)}{\sum_{ui' \in U} \exp(s(\mathbf{z}_u^1, \mathbf{z}_{ui'}^2)/\tau)} \quad (15)$$

$$L_c^{u'} = \sum_{u \in U} -\log \frac{\exp(s(\mathbf{z}_u^2, \mathbf{z}_{ui}^1)/\tau)}{\sum_{ui' \in U} \exp(s(\mathbf{z}_u^2, \mathbf{z}_{ui'}^1)/\tau)} + \sum_{v \in V} -\log \frac{\exp(s(\mathbf{z}_u^2, \mathbf{z}_{ui}^2)/\tau)}{\sum_{ui' \in U} \exp(s(\mathbf{z}_u^2, \mathbf{z}_{ui'}^2)/\tau)} \quad (16)$$

$$L_c = L_c^u + L_c^{u'} \quad (17)$$

其中, τ 表示一个温度超参数; $s(\cdot)$ 表示余弦相似度。项目图同理。具体公式如下:

$$L_b = L_b^v + L_b^{v'} \quad (18)$$

2.6 模型预测和训练

研究中对 3 个视图进行聚合, 并通过跨层交叉对比学习来均衡特征信息, 得到用户 u 和项目 v 的多个表示, 并通过内积预测用户对物品的预测评分:

$$\hat{y}(u, i) = \mathbf{z}_u^T \mathbf{z}_i \quad (19)$$

为了将推荐任务与对比学习任务结合起来, 采用多任务训练策略对整个模型进行优化。采用贝叶斯个性化排名 (Bayesian Personalized Ranking, BPR) 作为推荐监督的损失函数, 具体如下:

$$L_{\text{BPR}} = \sum_{(u, i, j) \in O} -\ln \sigma(\hat{y}_{ui} - \hat{y}_{uj}) \quad (20)$$

其中, $O = \{(u, i, j) \mid (u, i) \in O^+, (u, j) \in O^-\}$ 表示训练数据集, σ 表示 Sigmoid 函数。

3 实验与分析

3.1 数据集和评价指标

本文使用 2 个基准数据集来评估 MACCL 的有效性: Amazon-book 和 Tmall。这 2 个不同领域的数据集是公开可访问的, 并且在大小和稀疏性上也各不相同, 这使得本文的实验更有说服力。表 1 详细列出了这 2 个数据集的统计信息。

表 1 数据集统计
Table 1 Dataset statistics

数据集	Amazon-book	Tmall
#Users	78 578	47 939
#Items	77 801	41 390
#Interactions	3 190 224	2 357 450

(1) Amazon-book: 该数据集基于用户对书籍的评分, 评分范围从 1 到 10, 还包括隐性评分。

(2) Tmall: 包含用户在天猫平台上的购买记录。

删除数据集中出现次数少于 10 次的项目, 以保证交互数据的质量。每个训练样本的最大长度设置为 20。每个数据集的用户按 8 : 1 : 1 的比例分成训练集、验证集和测试集。采用 2 个广泛使用的 Recall@N 和归一化折损累计增益 (Normalized Discounted Cumulative Gain) NDCG@N 作为评价指标评估推荐性能, 这里 N 值分别为 5 和 10。Recall@N 表示一个人的评级项目出现在前 N 个推荐项目中的百分比。NDCG@N 是针对排序结果的评价指标, 用于评估排序的准确性。

3.2 实验设置

本文模型和算法中选择使用的操作系统为 Windows10, GPU 为 Nvidia RTX3070, 实验环境基于 Python3.7 和 Pytorch1.7.1 搭建。对于模型中使用的超参数, 经过反复实验后设置如下: 损失函数中的超参 λ 设置为 0.001, 温度超参设置为 0.6, 参数初始化采用 Xavier 方式, 优化器为 Adam, 其学习率为 0.001, 嵌入大小设置为 64, 数据集批量训练大小

为 1 024。GCN 层的深度设置为 2。

3.3 实验性能比较

本文的方法与先进的基线条件对比的实验结果见表 2。从表 2 中发现:与基线模型相比,本文提出

的方法在 2 个数据集上总体来看都更优越,模型的 Recall@ *N* 和 NDCG@ *N* 指标在 2 个数据集上分别提升了 37% 和 34%。表明 2 种视图增强和多视图跨层交叉对比学习可以优化模型性能。

表 2 性能统计

Table 2 Performance statistics

数据集	指标	SR-GNN	GCE-GNN	GRU4Rec	LightGCN	SGL	HCCF	DuoRec	MACCL
Amazon-books	Recall@ 5	0. 137 0	0. 176 2	0. 010 5	0. 011 7	0. 327 4	0. 354 6	0. 336 4	0. 407 1
	Recall@ 10	0. 248 1	0. 253 7	0. 037 1	0. 099 6	0. 431 3	0. 478 3	0. 390 6	0. 422 5
	NDCG@ 5	0. 201 7	0. 243 9	0. 018 2	0. 236 5	0. 249 8	0. 334 2	0. 426 1	0. 458 2
	NDCG@ 10	0. 236 9	0. 256 1	0. 025 8	0. 209 0	0. 312 5	0. 359 5	0. 468 3	0. 492 1
Tmall	Recall@ 5	0. 116 8	0. 205 7	0. 088 5	0. 255 3	0. 268 6	0. 201 5	0. 358 5	0. 365 8
	Recall@ 10	0. 174 2	0. 239 0	0. 984 6	0. 378 9	0. 446 2	0. 298 2	0. 396 1	0. 421 7
	NDCG@ 5	0. 128 9	0. 214 8	0. 075 9	0. 154 3	0. 183 9	0. 352 8	0. 347 9	0. 405 9
	NDCG@ 10	0. 200 6	0. 259 2	0. 083 5	0. 208 7	0. 246 3	0. 416 9	0. 401 6	0. 457 0

3.4 消融研究

为了验证 MACCL 中的视图增强和跨层交叉对比学习对模型的影响,对关键部分进行深入研究,把模型与 2 个变体进行比较。以此来检查主要组件对最终性能的影响。

- (1) MACCL-A: 删除随机添加噪声的视图增强方式。
- (2) MACCL-B: 删除邻域增强的方式。
- (3) MACCL-C: 删除跨层交叉对比学习。

消融实验结果见表 3。从表 3 可以得出以下结论:去除跨层交叉对比学习后,模型的性能发生了显著下降。表明对比融合可以缓解稀疏数据在传播过程中对邻居实体的感知不均衡。从 MACCL-A 可看出,邻域增强的方法是可行的,但是作用于数据丰富的数据集效果更好。随机添加噪声的增强方法对于模型略有提升。证明了多种增强方法对模型提升性能有一定的帮助。

表 3 消融实验

Table 3 Ablation experiment

数据集	指标	MACCL-A	MACCL-B	MACCL-C	MACCL
Amazon-books	Recall@ 5	0. 312 9	0. 174 2	0. 113 5	0. 407 1
	Recall@ 10	0. 335 4	0. 190 3	0. 167 2	0. 422 5
	NDCG@ 5	0. 278 1	0. 118 2	0. 109 4	0. 458 2
	NDCG@ 10	0. 300 7	0. 136 4	0. 112 8	0. 492 1
Tmall	Recall@ 5	0. 152 4	0. 148 0	0. 146 2	0. 365 8
	Recall@ 10	0. 138 3	0. 152 6	0. 120 3	0. 421 7
	NDCG@ 5	0. 112 8	0. 126 5	0. 118 2	0. 405 9
	NDCG@ 10	0. 132 6	0. 152 7	0. 132 9	0. 457 0

3.5 数据稀疏实验

为了验证 MACCL 在面对稀疏数据的情况下是否能很好学习节点之间的特征,表 4 给出了稀疏实验结果。依据交互数据稀疏程度的不同,交互次数为 15~20 次的为一组,20~25 次的为一组,将测试集分别生成了 3 组。比较 SGL, HCCF 和 MACCL 这 3 组交互数据 Recall@ 20 和 NDCG@ 20 的大小。从表 4 中可以看出, MACCL 的性能要优于 SGL 和

HCCF。表明 MACCL 依然可以进行高质量的推荐。

表 4 数据稀疏实验分析

Table 4 Experimental analysis of data sparsity

数据集	指标	SGL	HCCF	MACCL
Amazon-book	NDCG@ 10	0. 312 5	0. 359 5	0. 422 5
	Recall@ 10	0. 431 3	0. 478 3	0. 492 1
Tmall	NDCG@ 10	0. 246 3	0. 416 9	0. 457 0
	Recall@ 10	0. 446 2	0. 298 2	0. 421 7

3.6 参数敏感

在本研究中,重点研究了超参数对推荐模型性能的影响,其中包括温度参数 τ 和损失参数 λ 。

为了全面评估 τ, λ 的影响,保持其他设置不变,调整了这 2 个超参数的取值。通过在数据集上绘制 NDCG@ 20 和 Recall@ 20 的分数,能够清晰地观察到对模型性能的具体影响。

表 5 展示了在 Amazon-book 数据集上调整温度参数 τ 时的结果。由表 5 观察到,在该数据集上,最优的

温度参数 τ 为 0.5。当 τ 的取值偏离 0.5 时,不论是过大、还是过小,模型性能均呈现出平缓下降的趋势。

进一步地,对损失权重参数 λ 进行了测试,涵盖了多个取值($\{1e-4, 1e-5, 1e-6, 1e-7, 1e-8\}$)。损失超参数分析结果见表 6。从表 6 中可以明显看出,当 λ 被设置为 $1e-7$ 时,模型表现达到最佳状态。这一发现强调了适当选择损失权重参数对于整体损失的优化至关重要,从而使得推荐模型在 Amazon-book 数据集上取得了最佳性能。

表 5 温度超参数分析
Table 5 Analysis of temperature hyperparameters

数据集	指标	0.1	0.3	0.5	0.7	0.9
Amazon-book	NDCG@ 10	0.386 1	0.375 9	0.422 5	0.371 8	0.354 9
	Recall@ 10	0.476 9	0.482 3	0.492 1	0.443 7	0.439 0

表 6 损失超参数分析
Table 6 Analysis of loss hyperparameters

数据集	指标	1e-4	1e-5	1e-6	1e-7	1e-8
Amazon-book	NDCG@ 10	0.394 3	0.402 8	0.418 6	0.422 5	0.387 4
	Recall@ 10	0.437 2	0.440 1	0.446 5	0.492 1	0.423 0

4 结束语

本文提出了一个基于多视图增强的跨层交叉对比学习的推荐算法框架 MACCL,该框架通过构建 3 种视图并使用 2 种视图增强的方法,同时引入一种新的对比学习方法、即多视图跨层交叉对比学习来解决推荐问题。MACCL 在视图增强时,考虑到单一的增强方法存在局限性,采用随机添加噪音和结合关系注意力的增强领域的方法。多视图融合跨层对比学习充分利用不同视图的层嵌入。计算得到对比损失与其他损失来共同训练模型。在 2 个公开的数据集上进行了大量实验,实验结果表明 MACCL 比现有先进的方法取得了更好的性能,且在抵抗数据稀疏方面表现出了强大的能力。在未来的工作中将继续研究视图增强和多视图融合方法,探索新的视角,进一步提升推荐性能。

参考文献

[1] XIE Yueqi, ZHOU Peilin, KIM S. Decoupled side information fusion for sequential recommendation [C]// Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2022; 1611-1621.

[2] FANG Hui, ZHANG Danning, SHU Yiheng, et al. Deep learning for sequential recommendation: Algorithms, influential factors, and evaluations [J]. ACM Transactions on Information Systems

(TOIS), 2020, 39(1):1-42.

[3] ZHANG Yan, GUO Bin, WANG Qianru, et al. SeqRec: sequential - based recommendation model with long - term preference and instant interest [J]. Journal of Zhejiang University (Engineering Science), 2020, 54(6):1177-1184.

[4] KANG Wangcheng, MCAULEY J. Self - attentive sequential recommendation [C]// Proceedings of 2018 IEEE International Conference on Data Mining (ICDM). Piscataway, NJ: IEEE, 2018:197-206.

[5] 黄立威,江碧涛,吕守业,等. 基于深度学习的推荐系统研究综述 [J]. 计算机学报, 2018, 41(7):1619-1647.

[6] 邴睿,袁冠,孟凡荣,等. 多视图对比增强的异质图结构学习方法 [J]. 软件学报, 2023, 34(10):4477-4500.

[7] 张少东,杨兴耀,于炯等. 基于对比学习和傅里叶变换的序列推荐算法 [J]. 电子科技大学学报, 2023, 52(4):610-619.

[8] GUO Kaifeng, ZENG Guolei. Graph convolutional network and self-attentive for sequential recommendation [J]. PeerJ Computer Science, 2023, 9: e1701.

[9] MANESSI F, ALESSANDRO R, MARIO M. Dynamic graph convolutional networks [J]. Pattern Recognition, 2020, 97: 107000.

[10] RENDLE S, FREUDENTHALER C, SCHMIDT-THIEME L. Factorizing personalized Markov chains for next - basket recommendation [C]//Proceedings of the 19th International Conference on World Wide Web. New York: ACM, 2010: 811-820.

[11] CHENG Chen, YANG Haiqin, LYU M R, et al. Where you like to go next: Successive point-of-interest recommendation [C]// Proceedings of the Twenty-Third International Joint Conference on Artificial Intelligence (IJCAI'13). New York: ACM, 2013: 2605-2611.

[12]李璐. 基于深度学习的序列推荐算法研究[D]. 济南: 山东建筑大学, 2023.

[13]SUN Fei, LIU Jun, WU Jian, et al. BERT4Rec: Sequential recommendation with bidirectional encoder representations from transformer[J]. arXiv preprint arXiv,1904.06690, 2019.

[14]HIDASI B, KARATZOGLOU A, BALTRNAS L, et al. Session-based recommendations with recurrent neural networks[J]. arXiv preprint arXiv,1511.06939, 2015.

[15]HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation,2010, 9 (8): 1735–1780.

[16]ASISH B, WHARTON Z, LIU Yonghuai, et al. SR-GNN: Spatial relation-aware graph neural network for fine-grained image categorization[J]. IEEE Transactions on Image Processing, 2022,31: 6017–6031.

[17]WANG Ziyang, WEI Wei, GAO Cong, et al. Global context enhanced graph neural networks for session-based recommendation [C]// Proceedings of the 43rd international ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2020;602–613.

[18]ZHANG Zhen, FAN Wu, LEE W S. Factor graph neural networks [J]. Advances in Neural Information Processing Systems,2020,33: 8577–8587.

[19]WANG X, HE X, WANG M, et al. Neural graph collaborative filtering[C]// Proceedings of the 42nd international ACM SIGIR conference on Research and development in Information Retrieval. New York:ACM, 2019;165–174.

[20]PROCOPIO L, TRIPODI R, NAVIGLI R. SGL: Speaking the graph languages of semantic parsing via multilingual translation [C]// Proceedings of 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. ACL, 2021;325–337.

[21]WEI Yinwei, WANG Xiang, LI Qi, et al. Contrastive learning for cold-start recommendation[J]. arXiv preprint arXiv,2107.05315, 2021.

[22]QIU Ruihong, HUANG Zi, YIN Hongzhi, et al. Contrastive learning for representation degeneration problem in sequential recommendation [C]//Proceedings of the fifteenth ACM international Conference on Web Search and Data Mining. New York:ACM,2022;813–823.

[23]HE Xiangnan, DENG Kuan, WANG Xiang, et al. LightGCN: Simplifying and powering graph convolution network for recommendation[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York:ACM, 2020;639–648.