

文章编号: 2095-2163(2023)11-0112-07

中图分类号: TP183; TM743

文献标志码: A

# 基于对比学习的图书推荐系统冷启动研究

董昊焯, 樊重俊

(上海理工大学 管理学院, 上海 200093)

**摘要:** 随着互联网时代的发展,图书零售线上占比越来越多,图书推荐系统应运而生。在推荐系统中,推荐纯冷启动项目是一个长期存在的问题。在没有任何关于冷启动项目的历史交互情况下,协作过滤(CF)方案不能利用协同信号来推断用户对这些图书的偏好。为了解决这个问题,已经进行了广泛的研究,如将图书辅助信息(内容特征等)纳入CF方案。但是由于很少探索内容特征和协作嵌入之间的关系,导致冷启动推荐性能并不理想。在本文中,重新定义了冷启动项目的表示学习,设计了一个基于对比学习的新目标函数,并提出了一个基于对比学习的冷启动推荐框架。具体来说,该框架由对比对组织、对比嵌入和对比优化三个模块组成,允许在内容表示中为热启动项和冷启动项保留协作信号。通过在2个可公开访问的数据集上进行的广泛实验,观察到提出的对比学习冷启动框架在热启动和冷启动场景中都比最先进的方法取得了显著改进。

**关键词:** 图书推荐系统; 对比学习; 冷启动推荐; 协同过滤

## Study on cold-start of book recommendation system based on comparative learning

DONG Haoye, FAN Chongjun

(Business School, University of Shanghai for Science and Technology, Shanghai 200093, China)

**Abstract:** With the development of the Internet era, more and more books are sold online, and the book recommendation system has emerged. In the recommendation system, recommending pure cold-start items is a long-standing problem. In the absence of any historical interaction with cold-start items, collaborative filtering (CF) schemes cannot use collaborative signals to infer user preferences for these books. To address this issue, extensive research has been undertaken, such as incorporating book assisted information (content characteristics, etc.) into CF schemes. However, the relationship between content characteristics and collaborative embeddings is rarely explored, resulting in unsatisfactory performance of cold-start recommendation. This paper redefines the presentation learning of cold-start projects, designs a new objective function based on contrast learning, and proposes a cold-start recommendation framework based on contrast learning. Specifically, the framework consists of three modules: contrast pair organization, contrast embedding, and contrast optimization, which allow us to preserve collaboration signals for hot and cold start items in content presentation. Through the extensive experiments on two publicly accessible datasets, the results demonstrate that the proposed contrast learning cold-start framework achieves significant improvements over state-of-the-art approaches in both hot start and cold start scenarios.

**Key words:** book recommendation system; comparative learning; cold-start recommended; collaborative filtering

## 0 引言

近几年,随着大数据、物联网、人工智能、5G的蓬勃发展,互联网产生的数据也与日俱增,在面对海量数据的情况下,人类无法迅速精准地找到有价值的信息。为了解决数据过载的问题,推荐系统应运而生,可以从海量的互联网数据中挖掘出用户可能

感兴趣的商品,做出个性化推荐,有效降低了人们在互联网上寻找自己感兴趣信息时所消耗的时间。随着相关研究的逐渐成熟,推荐系统通过强大的信息过滤技术为很多领域的发展都提供了强有力的帮助,比如,电商领域天猫、亚马逊等平台的应用,娱乐领域快手短视频、qq音乐等App的普及,都通过推荐系统大大提升了软件的使用频率和用户数量。

**基金项目:** 2020教育部哲学社会科学重大课题(2020-2023(20JZD010))。

**作者简介:** 董昊焯(1998-),男,硕士研究生,主要研究方向:人工智能理论及应用。

**通讯作者:** 樊重俊(1963-),男,博士,教授,主要研究方向:人工智能、电子商务。Email: fanchongjun2022@163.com

**收稿日期:** 2023-09-19

作为大家日常生活中放松、学习、自我提升的重要工具,图书依然是人们不可或缺的精神食粮。在《2021 年中国图书市场研究报告》中显示,图书行业正在逐步加入新的商业模式中,网上书店就是新模式下的产物,且已形成了规模,并逐步占有大部分市场份额,因此线上图书推荐系统的应用必要性也日益凸显。线上图书推荐系统可以根据每个用户与电子图书的交互数据,分析挖掘用户行为,实现智能化的图书精准推荐。

但与此同时,对于图书推荐系统而言,冷启动的问题也不容忽视。平台中并非所有图书都有充足的可用历史数据,随着新书籍的不断上架,系统内部没有充足的数据支撑,经典的协同过滤等方案无法利用协同相似度来推断用户对这些图书的偏好,很大程度上降低了推荐准确性。从而导致用户信赖度降低,失去用户粘性,最终用户数量减少,对企业造成了极大影响,因此,解决推荐系统冷启动问题迫在眉睫。

针对上述问题,论文提出了一种基于对比学习的冷启动推荐框架,可以显著提高图书冷启动情况下的推荐准确性,对此问题的研究具有迫切的意义。

## 1 相关工作

### 1.1 对比学习

对比学习作为自监督学习的代表性算法,目前已经广泛应用于计算机视觉<sup>[1-7]</sup>和自然语言处理<sup>[5-6]</sup>领域。就是通过从一些负样本对中识别出正对,最大化了不同表示之间的互信息,从而发现不同视图之间共享的语义信息。为此,Oord 等学者<sup>[8]</sup>提出了一种概率对比损失以最大限度地保留观测和上下文信号之间的互信息。对于推荐系统,一些模型<sup>[9]</sup>采用对比学习来优化用户和项目的表示。然而,这些方法更侧重于协作或内容空间的表示。

相比之下,将协作嵌入和特征表示视为 2 个不同的方面,并最大化彼此间的互信息,以便于从内容信息中捕捉协作信号。

### 1.2 推荐系统冷启动

解决推荐系统冷启动问题的常见方法是利用辅助信息和上下文信息<sup>[10]</sup>,以及来自其他领域的信息<sup>[11]</sup>来推荐物品,但是随着《通用数据保护条例》的颁布,数据在政策的限制下分散在不同的平台中,可获取的信息越来越少。传统的基于内容推荐的方法使用用户特征和项目特征来扩充数据,虽然提高了

推荐的准确率,但会造成很明显的“长尾效应”。文献<sup>[12]</sup>提出了一种局部集体嵌入学习方法,通过项目的属性和过去的用户偏好进行矩阵分解,在新闻推荐领域得到了很好的效果,但在其他领域推荐精度亟待提高。Gao 等<sup>[13]</sup>提出了一种融合 CNN 和 GAN 模型的基于 Deep Q-Network 的推荐框架,在 DRCCR 中还提供了一种将卷积序列嵌入的推荐模型,以捕获用户正反馈的序列偏好。Feng 等学者<sup>[14]</sup>使用奇异值分解模型对未评级项目进行预处理,以增加显式反馈数据的密度,再将提取的特征进行融合,得到最终的用户特征矩阵和产品特征矩阵。本文将通过最大化互信息来明确显示的建模内容与协同过滤信息之间的相关性。

## 2 对比学习冷启动框架

研究提出了一个基于对比学习的冷启动推荐框架。如图 1 所示。该框架主要由 3 部分组成:对比对组织、对比嵌入网络、对比优化。在下文中,将详细介绍每一部分的设计内容。

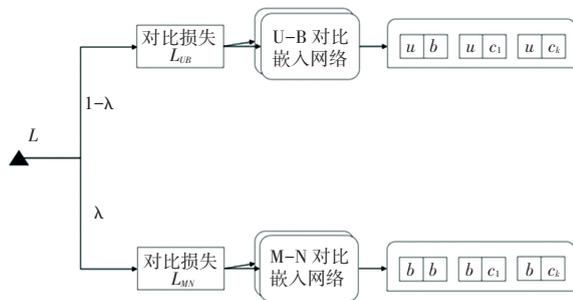


图 1 对比学习推荐系统框架示意图

Fig. 1 The framework diagram of comparative learning recommendation system

### 2.1 对比对组织

对比学习的核心思想是构造正负样本,将语义相似的实例所组成的正样本从语义不相似的实例所组成的负样本中识别出来,并将正样本和负样本在特征空间中进行对比,学习样本的特征表示。因此,在图书推荐系统中,将用户和图书组成  $U - B$  和  $M - N$  对比对进行学习研究。

#### 2.1.1 $U - B$ 对比对

研究中从历史数据中进行寻找,将观察到的用户 (user) — 书籍 (book) 对视为正样本,如图 2 所示。同时,随机抽取  $K$  项尚未被用户  $U$  购买的书籍,如  $(c_1, c_2, c_3, \dots, c_k)$ ,并与用户配对以建立负样本对。形式上,可以将正  $U - B$  和负  $U - B$  对定义为:

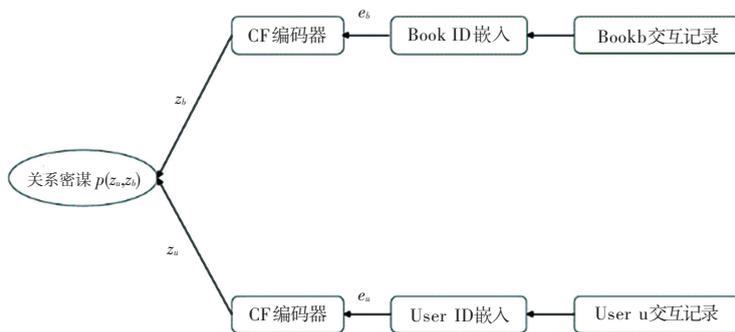


图2 U-B 部分框架

Fig. 2 U-B part frame

$$\{(u, b), (u, c_1), (u, c_2), (u, c_3), \dots, (u, c_k)\} \quad (1)$$

与负样本对相比,正样本对包含相似的协同信号,因此,这样更有助于发现由交互动作所传递的协作信号。

### 2.1.2 M-N 对比对

与 U-B 对比对不同, M-N 对比对采用了自判别任务来最大化项目的 2 种不同表示的相互信息。如图 2 所示,为了构建配对 b 将其设为锚点,并将其与自身连接作为正对,这揭示了同一项目 b 的 2 个表示之间的语义相似性。

相反,锚点与其他项目组织的否定对在语义上是不相似的。由图 1 看到,将项目配对在一起从而获得 M-N 对比对:

$$\{(b, b), (b, c_1), (b, c_2), (b, c_3), \dots, (b, c_k)\} \quad (2)$$

其中, (b, b) 是正对,其他为负对。

## 2.2 对比嵌入网络

基于对比学习样本,设计了 U-B、M-N 对比嵌入网络来表示用户和书籍,并定义了关系密度函数来计算每个样本对的相关性。

### 2.2.1 U-B 对比嵌入网络

为了对用户-图书交互矩阵进行建模,从由参数矩阵定义的查找表中获取对应的 id 嵌入(如  $e_u$ ,  $e_b$ ):

$$E = (e_{u1}, e_{u2}, \dots, e_{uY}, e_{b1}, e_{b2}, \dots, e_{bZ}) \quad (3)$$

然后,通过一个共享的 CF 编码器来学习用户-图书的协作嵌入(见图 2),可以通过各种模型来实现,例如基于 MF<sup>[15-17]</sup>模型、基于图神经网络<sup>[18-20]</sup>模型等。在此项工作中,运用了简单且有效的实现方法,基于 LightGCN<sup>[18]</sup>和 MF<sup>[16]</sup>,将其表述为:

$$\begin{cases} z_u = \mathcal{E}(e_u, \{e_c | c \in N_u\}) \\ z_b = \mathcal{E}(e_b, \{e_v | v \in N_b\}) \end{cases} \quad (4)$$

其中,  $\mathcal{E}$  是将 id 嵌入 ( $e_b, e_u$ ) 作为输入的 CF 编码器;  $N_u$  表示用户  $u$  已经购买的图书集合;  $N_b$  表示与图书  $b$  进行过交互的用户集合。在获得了用户-图书对(即  $z_u$  和  $z_b$ )的协作嵌入后,定义了关系密度函数  $p(z_u, z_b)$  来衡量其相关性:

$$p(z_u, z_b) = e^{\frac{z_u^T z_b}{\tau}} \quad (5)$$

其中,  $\tau$  为温度系数<sup>[1]</sup>,用内积来计算相关性,将其他非负函数的探索留在未来的工作中。

### 2.2.2 M-N 对比嵌入网络

此嵌入网络用于对图书协作信号和内容信息两个方面之间的相关性进行评分。M-N 部分框架如图 3 所示,即由 2 块区域构成:分别对图书的特征表示和协同嵌入进行建模。其中,协同嵌入的方式与 2.2.1 节 U-B 对比嵌入网络中的方法相同。

为了表示图书的内容信息,应用了一个预先训练好的深度学习模型进行特征提取<sup>[21]</sup>,获得 M-N 对比对中图书  $c$  的特征向量  $x_c$ ,再运用多层感知器进行特征编码获得  $h_c$ :

$$h_c = \mathbf{W}^{(2)} \phi(\mathbf{W}^{(1)} x_c + \mathbf{b}^{(1)}) + \mathbf{b}^{(2)} \quad (6)$$

其中,  $\mathbf{W}^{(\cdot)}$  表示编码器的可训练矩阵;  $\mathbf{b}^{(\cdot)}$  表示编码器的偏置向量;  $h_c$  是图书的期望特征表示,提取了内容特征且最大限度地保留了与协作信号相关的信息。在这种特征表示下,可以计算用户和冷启动项目之间的相关性。

在通过上述方法获得  $h_c$  与  $z_b$  后,使用以下关系密度函数对其相关性进行评分:

$$q(h_c, z_b) = e^{\frac{1}{\tau} \cdot \frac{h_c^T z_b}{\|h_c\| \cdot \|z_b\|}} \quad (7)$$

为了保持内容信息的完整,可将向量进行归一化处理,测量单位空间中的比值。

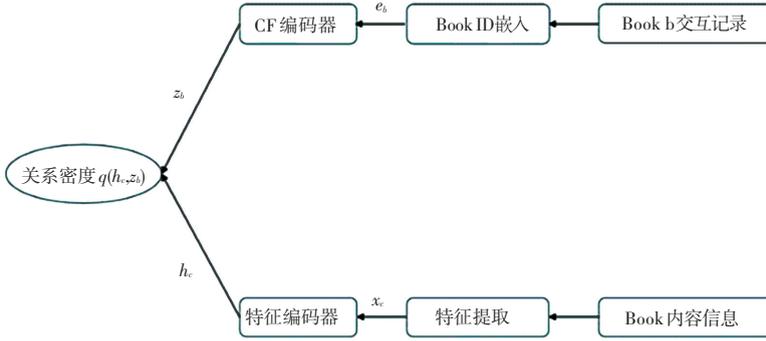


图 3 M-N 部分框架

Fig. 3 M-N part frame

2.3 最终目标函数

为了使交互信息最大化,运用对比学习的方法

来优化模型的参数,结合定义的关系密度函数,得到最终的目标函数:

$$L = \lambda L_{MN} + (1 - \lambda) L_{UB} + \eta \| \Theta \|_2^2$$

$$L = -\lambda E_{b \in B} \ln \frac{\exp(\frac{\mathbf{h}_b^T \mathbf{z}_b}{\|\mathbf{h}_b\| \cdot \|\mathbf{z}_b\|} \cdot \frac{1}{\tau})}{\exp(\frac{\mathbf{h}_b^T \mathbf{z}_b}{\|\mathbf{h}_b\| \cdot \|\mathbf{z}_b\|} \cdot \frac{1}{\tau}) + \sum_{k=1}^K \exp(\frac{\mathbf{h}_b^T \mathbf{z}_{c_k}}{\|\mathbf{h}_b\| \cdot \|\mathbf{z}_{c_k}\|} \cdot \frac{1}{\tau})} -$$

$$(1 - \lambda) E_{(u, b \in O)} \ln \frac{\exp(\frac{\mathbf{z}_u \mathbf{z}_b^T}{\tau})}{\exp(\frac{\mathbf{z}_u \mathbf{z}_b^T}{\tau}) + \sum_{k=1}^K \exp(\frac{\mathbf{z}_u \mathbf{z}_{c_k}^T}{\tau})} + \eta \| \Theta \|_2^2 \quad (8)$$

3 实验与结果

在本节中,首先介绍了用于本次实验的数据集,并描述了实验设计。然后,为了评估本文提出对比学习冷启动推荐框架的准确性,将提出的方法与热启动、冷启动和所有项目的真实数据中的样本进行了比较,得到了最终的实验结果。

3.1 实验设置

3.1.1 数据集

为了评估本文提出“图书冷启动推荐系统”的有效性,分别在 2 个真实的数据集中进行了广泛的实验,包括由弗莱堡大学 Cai-Nicolas Ziegler 发布的 Book-Crossing Dataset 和由 Amazon product 中提供的一些用户—图书的购买数据,信息见表 1。

表 1 数据集摘要

Tab. 1 Data set summary

数据	Inter	User	Warm	Cold
Book-Crossing	483 203	35 212	49 265	9 836
Amazon product	308 212	20 838	38 942	5 682

对于每个数据集,随机抽取了一些图书作为冷启动项目,并按照 1 : 1 的比例分为冷启动条件下的验证集和测试集。此外,将其他的图书交互数据按照 8 : 1 : 1 的比例分为训练集、热启动验证集、热启动测试集。结合所有的验证集对目标函数的超参数进行优化,并通过测试集对最终模型的性能进行评估。

3.1.2 对比参照

研究中,将本文提出的模型与其他几种冷启动推荐系统的模型进行比较。除了如较为常用的基于鲁棒性(即 DropoutNET、MTPR)和基于约束的方法(即 CB2CF, Heater)之外,还引入了基于内容的模型(即 DUIF)来突出本文提出的冷启动推荐模型的准确性。此外,通过比较 MF-BPR 与 LightGCN 的结果来强调本文所提出的目标函数的有效性。对此,拟做阐释分述如下。

(1) DropoutNet<sup>[22]</sup>。该方法改变了模型训练方式,在训练过程中加入了 dropout 的机制,使得模型不过度依赖 ID embedding,而是其他内容特征。从

而减小了不好的 ID embedding 的影响。

(2) Heater<sup>[23]</sup>。该方法使用误差平方和损失 (SSE) 来对内容信息中的协作嵌入进行建模,同时利用随机训练的方法来提升有效性。

(3) DUIF<sup>[24]</sup>。与基于 CF 的模型不同,这种方法在不对 CF 信号建模的情况下学习用户对项目特征的应用,从根本上避免了冷启动问题。

(4) MF-BPR<sup>[17]</sup>。该方法根据过去的交互学习潜在向量(即协作嵌入)来表示用户和项目,并通过测量所学习的表示之间的相似性来预测其相似性。

(5) LightGCN<sup>[18]</sup>。基于图卷积网络<sup>[25-26]</sup>,学习高阶 CF 信号,并将其注入到协作嵌入中,优化推荐。

### 3.1.3 度量标准

分别对 2 个数据集中的热启动项、冷启动项和所有项目(热启动项与冷启动项相结合)进行评估,采用广泛应用于推荐系统领域的评价指标:召回率 ( $recall@K$ ) 以及归一化折损累计增益 ( $NDCG@K$ )。默认情况下,设置  $K = 10$ 。

表 2 在 2 个数据集上与基于 BPR 损失的推荐模型进行比较

Tab. 2 Comparison of the recommendation model based on BPR losses on both data sets

Data		MF - BPR	LightGCN	$CEN_{MF}$	$CEN_{GCN}$
Book-Crossing	Warm	0.058 9	0.059 2	0.088 7	<b>0.089 3</b>
	Cold	0.000 7	0.001 2	<b>0.015 1</b>	0.013 2
	All	0.039 7	0.039 3	0.062 8	<b>0.069 7</b>
Amazon product	Warm	0.067 4	0.067 2	<b>0.090 1</b>	0.089 2
	Cold	0.000 8	0.000 7	<b>0.021 2</b>	0.019 8
	All	0.049 8	0.050 1	0.072 1	<b>0.073 3</b>

表 3 在 2 个数据集上与冷启动推荐模型比较

Tab. 3 Comparison of the cold-start recommendation model on both data sets

		Recall@ 10					Recall@ 10				
		DUIF	DropoutNET	Heater	对比学习	增长率/%	DUIF	DropoutNET	Heater	对比学习	增长率/%
Book-crossing	Warm	0.032 8	0.028 7	0.041 5	<b>0.088 7</b>	113.73	0.041 8	0.044 5	0.043 2	<b>0.061 8</b>	38.88
	Cold	<u>0.007 2</u>	0.002 9	0.003 2	<b>0.015 1</b>	109.72	<u>0.008 0</u>	0.006 2	0.007 8	<b>0.012 1</b>	51.25
	All	0.30 5	0.024 1	<u>0.031 0</u>	<b>0.062 8</b>	102.58	0.039 7	0.038 4	0.039 8	<b>0.047 8</b>	20.10
Amazon product	Warm	0.015	0.042 6	<u>0.058 1</u>	<b>0.090 1</b>	55.08	0.037 8	0.039 9	<u>0.041 8</u>	<b>0.064 6</b>	54.55
	cold	0.013 4	0.0091	0.013 2	<b>0.021 2</b>	58.21	<u>0.008 5</u>	0.004 8	0.007 6	<b>0.018 3</b>	115.29
	All	0.034 2	0.028 2	0.039 9	<b>0.072 1</b>	80.70	0.032 1	0.036 5	0.039 2	<b>0.057 7</b>	47.19

### 3.2.2 关于冷启动的建议

分析实验结果,得到以下结论:

分析表 3,在  $recall@10$  和  $NDCG@10$  的结果中,对于训练集中未出现过的图书(即冷启动项

### 3.1.4 参数设置

为了公平起见,将所有模型的协同嵌入维数设置为 64。在超参数方面,使用网格搜索的方法<sup>[27-28]</sup>;学习率在  $\{0.000 1, 0.001, 0.01, 0.1\}$  中调整,正则化权重在  $\{0.000 1, 0.001, 0.1\}$  中搜索。此外,采用提前停止策略<sup>[27]</sup>,如果在验证集上连续 10 次迭代  $recall@10$  没有增加,则停止训练。

## 3.2 结论

### 3.2.1 关于目标函数的性能比较

在本文中,提出了一个基于对学习方法的目标函数,并运用了一个具有灵活编码器的通用框架。为了证明目标函数的合理性,将配备了基于 MF 和基于 GCN 的 CF 编码器 ( $CEN_{MF}$  和  $CEN_{GCN}$ ) 与 MF - BPR 和 LightGCN 进行比较,通过 BPR 损失函数进行优化。分析实验结果见表 2、表 3,得出结论为:

$CEN_{MF}$  和  $CEN_{GCN}$  无论在冷启动、还是热启动情况下均显著优于 MF - BPR 和 LightGCN,因此本文所提出的目标函数能够有效地对协作嵌入进行建模,并提取与协作信号相关的特征。

目), DUIF 的性能大大优于其他方法。因为基于内容的模型中,用户是通过细化其交互的图书特征来表示的,这些特征通过与未观察到的图书相关联,因此是合理的。然而在基于内容过滤的模型中,用户

的协作嵌入和图书的特征表示之间存在差距。

通过分析表 2 的结果,可以发现针对冷启动设计的方法(DropoutNET、Heater)在冷启动的场景中优于  $MF - BPR$  和  $LightGCN$ ,这些方法均从图书特征中捕捉到了协作信号,有助于预测用户与冷启动图书之间的交互。

本文提出的图书冷启动推荐框架在所有情况下(冷启动、热启动、冷启动与热启动相结合)  $recall@10$  和  $NDCG@10$  均是优于上述最强性能的。其中,  $recall@10$  在 2 个数据集上比最强基线分别提高了 109.72%、58.21%,  $NDCG@10$  分别比基线提高了 51.25%、115.29%。可以归因于以下 2 个方面:

(1) 具有  $U - B$  对比学习方法的图书冷启动推荐框架有助于协同嵌入的建模。

(2)  $M - N$  互信息保留了更多与协作信号相关信息的特征表示。

### 3.3 深入分析

为了进一步探索本文提出的方法如何优化推荐,还进行了额外的实验来研究训练过程的梯度幅度。不同数量的对比负对中测试所提出的方法,并计算等式中的梯度幅度。记录了每个时期的梯度幅度状态,并在图 4 中展示了在 Book-Crossing 数据集  $Recall@10$  的相关学习曲线。

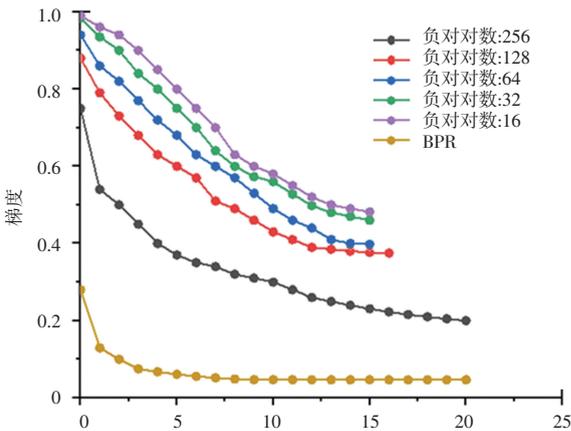


图 4 在 Book-Crossing 数据集  $Recall@10$  的相关学习曲线

Fig. 4 Related learning curve in the Book-Crossing dataset  $Recall@10$

通过分析平均梯度和性能,研究发现本文提出的方法比  $MF - BPR$  获得了更大的梯度幅度,性能也随着负对的增加而提高。

## 4 结束语

本文专注于图书冷启动推荐问题,在对比学习的基础上制定了一个新的目标函数来最大化  $U - B$

和  $M - N$  两种互信息,从而进一步设计了一个由对比对、对比嵌入网络、对比优化三部分组成的冷启动推荐框架。本文在 2 个数据集上进行了广泛的实验,实验结果验证了方法的有效性,无论在冷启动、还是暖启动方面推荐准确度均有较大的提升。该方法不仅提供了一种解决冷启动的方法,也在运用对比学习解决冷启动的方向上带来了一定的启发。此外,未来会进一步研究互信息最大化在其它领域的有效应用。

## 参考文献

- [1] CHEN Ting, KORNBLITH S, NOROUZI M, et al. A simple framework for contrastive learning of visual representations [C]// Proceedings of International Conference on Machine Learning. IMLS, 2020: 1-11.
- [2] GRILLJ B, STRUB F, ALTCHÉ F, et al. Bootstrap your own latent: A new approach to self-supervised learning [J]. arXiv preprint arXiv:2006.07733v1, 2020.
- [3] HE Kaiming, FAN Haoqi, WU Yuxin, et al. Momentum contrast for unsupervised visual representation learning [C]// Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE, 2020: 9729-9738.
- [4] MBAMALU G A N, EL-HAWARY M E. Load forecasting via suboptimal seasonal autoregressive models and iteratively reweighted least squares estimation [J]. IEEE Transaction on Power Systems, 1993, 8(1): 343-348.
- [5] KHOSLAP, TETERWAK P, WANG Chen, et al. Supervised contrastive learning [C]// Advances in Neural Information Processing Systems. Vancouver: NIPS Foundation, 2020, 33: 18661-18673.
- [6] CHI Zewen, DONG Li, WEI Furu, et al. InfoXLM: An information-theoretic framework for cross-lingual language model pre-training [J]. arXiv preprint arXiv:2007.07834v2, 2021.
- [7] LI Zheng, QIN Yan, HOU Shaodong, et al. Renewable energy system based on IFOA-BP neural network load forecast [J]. Energy Reports, 2020, 6(S9): 1585-1590.
- [8] OORD A V D, LI Yazhe, VINYALS O. Representation learning with contrastive predictive coding [J]. arXiv preprint arXiv:1807.03748, 2018.
- [9] ZHOU Chang, MA Jianxin, ZHANG Jianwei, et al. Contrastive learning for debiased candidate generation in large-scale recommender systems [J]. arXiv preprint cs.IR/2005.12964, 2020.
- [10] BARJASTEH I, FORSATI R, ROSS D, et al. Cold-start recommendation with provable guarantees: A decoupled approach [J]. TKDE, 2016, 28(6): 1462-1474.
- [11] HU Guangneng, ZHANG Yu, YANG Qiang. Conet: Collaborative cross networks for cross-domain recommendation [C]// Proceedings of the 27th ACM International Conference on Information and Knowledge Management (CIKM). Turin, Italy: ACM, 2018: 667-676.
- [12] SAVESKI M, MANTRACH A. Item cold-start recommendations: Learning local collective embeddings [C]// RecSys. New York, NY, USA: ACM, 2014: 89-96.
- [13] GAO Rong, XIA Haifeng, LI Jing, et al. DRCGR: Deep

- reinforcement learning framework incorporating CNN and GAN-based for interactive recommendation [C]//Proceedings of 2019 IEEE International Conference on Data Mining (ICDM). Beijing: IEEE, 2019; 1048–1053.
- [14] FENG Junmei, XIA Zhaoqiang, FENG Xiaoyi, et al. RBPR: A hybrid model for the new user cold start problem in recommender systems [J]. Knowledge-Based Systems, 2021, 214: 106732.
- [15] KOREN Y, BELL R, VOLINSKY C. Matrix factorization techniques for recommender systems [J]. Computer, 2009, 42(8): 30–37.
- [16] MNIH A, SALAKHUTDINOV R R. Probabilistic matrix factorization [C]//Advances in Neural Information Processing Systems. Montreal, Canada; NIPS Foundation, 2008; 1257–1264.
- [17] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: Bayesian personalized ranking from implicit feedback [C]//Proceedings of Conference on Uncertainty in Artificial Intelligence. Montreal, QC, Canada; DBLP, 2009; 452–461.
- [18] HE Xiangnan, DENG Kuan, WANG Xiang, et al. LightGCN: Simplifying and powering graph convolution network for recommendation [C]//Proceedings of International ACM SIGIR Conference on Research and Development in Information Retrieval. Xi'an; ACM, 2020; 639–648.
- [19] WANG Xiang, HE Xiangnan, WANG Meng, et al. Neural graph collaborative filtering [C]//Proceedings of the International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, NY, USA; ACM, 2019; 165–174.
- [20] WEI Yinwei, WANG Xiang, HE Xiangnan, et al. Hierarchical user intent graph network for multimedia recommendation [J]. arXiv preprint arXiv: 2110.14925v1, 2021.
- [21] WEI Ji, LI Xi, WU Fei, et al. Human-centric clothing segmentation via deformable semantic locality-preserving network [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2020, 30(12): 4837–4848.
- [22] VOLKOV M, YU Guangwei, POUTANEN T. Dropoutnet: Addressing cold start in recommender systems [C]//Advances in Neural Information Processing Systems. Long Beach: NIPS Foundation, 2017; 4957–4966.
- [23] ZHU Ziwei, SEFATI S, SAADATPANDAH P, et al. Recommendation for New Users and New Items via Randomized Training and Mixture-of-Experts Transformation [C]//Proceedings of International ACM SIGIR Conference on Research and Development in Information Retrieval. ACM, 2020; 1121–1130.
- [24] XUE Geng, ZHANG Hanwang, BIAN Jingwen, et al. Learning image and user features for recommendation in social networks [C]//Proceedings of the IEEE International Conference on Computer Vision. Kerkyra; IEEE Press, 2015; 4274–4282.
- [25] LIU Zhenguang, QIAN Peng, WANG Xiaoyang, et al. Combining graph neural networks with expert knowledge for smart contract vulnerability detection [J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(2): 1296–1310.
- [26] ZHUANG Yuan, LIU Zhenguang, QIAN Peng, et al. Smart contract vulnerability detection using graph neural network [C]//Proceedings of the Twenty-Ninth International Joint Conference on Artificial Intelligence and Seventeenth Pacific Rim International Conference on Artificial Intelligence (IJCAI-PRICAI-20). Yokohama, Japan; DBLP, 2020; 3283–3290.
- [27] JIANG Hao, WANG Wenjie, WEI Yinwei, et al. What aspect do you like: Multi-scale time-aware user interest modeling for micro-video recommendation [C]//Proceedings of the 28<sup>th</sup> ACM International Conference on Multimedia. ACM, 2020; 3487–3495.
- [28] YU Xuzheng, GAN Tian, WEI Yinwei, et al. Personalized item recommendation for second-hand trading platform [C]//Proceedings of the 28<sup>th</sup> ACM International Conference on Multimedia. ACM, 2020; 3478–3486.
- [29] WEI Ji, LI Xi, WEI Lina, et al. Context-aware graph label propagation network for saliency detection [J]. IEEE Transactions on Image Processing, 2020, 29: 8177–8186.