

基于图注意力对抗网络的社会化推荐系统

夏忠秀 张维玉* 翁自强 郭新超

(齐鲁工业大学(山东省科学院)计算机科学与技术学院 山东 济南 250353)

摘要 现有的推荐系统并不能很好地将社会影响力与潜在兴趣进行区分,同时也忽略了社交网络的图结构特征及其变化。针对以上不足,提出基于图注意力对抗网络的社会化推荐系统(GAASR)。利用对抗性网络将社会影响力和潜在兴趣进行分离;使用 Hadamard 投影的方法,获得上下文权重值;利用图注意力网络来学习社交嵌入的潜在向量,更精准地捕捉用户的社会结构。为了验证该推荐系统的性能,使用三个推荐系统数据集进行分析实验,实验结果表明 GAASR 优于目前流行的推荐方法,能够有效地提高推荐的准确率。

关键词 推荐系统 生成对抗网络 图注意力网络 社交网络

中图分类号 TP391

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.08.042

SOCIAL RECOMMENDATION SYSTEM BASED ON GRAPH ATTENTION ADVERSARIAL NETWORK

Xia Zhongxiu Zhang Weiyu* Weng Ziqiang Guo Xinchao

(School of Computer Science and Technology, Qilu University of Technology (Shandong Academy of Sciences), Jinan 250353, Shandong, China)

Abstract Existing recommendation systems cannot distinguish social influence from potential interest well, and ignore the graph structure characteristics and changes of social networks. In view of the above deficiencies, a social recommendation system based on graph attention adversarial network (GAASR) is proposed. Social influence and potential interest were separated by adversarial network. Hadamard projection method was used to obtain the values of context weight. The graph attention network was used to learn the potential vector of social embedding and capture the social structure of users more accurately. In order to verify the performance of the recommendation system, three recommendation system data sets were used for analysis experiments. The experimental results show that GAASR is better than currently popular recommendation methods, which can effectively improve the recommendation accuracy.

Keywords Recommendation system Generative adversarial network Graph attention network Social network

0 引言

随着在线社交网络的发展,人们也越来越愿意在社交网络平台上查看或发布信息、关注好友、评论感兴趣的物品。社会化推荐系统利用社会关系来提升推荐系统的性能^[1-2],它已成为推荐系统领域研究的热门方向之一,因此受到了研究人员的广泛关注。

社会化推荐系统由项目域和社交域两部分组成,

它们分别表示用户-物品交互和用户-用户连接。目前,融合社交关系信息来改进推荐系统是主流的推荐方法。TrustSVD^[3]在先进的推荐算法 SVD++^[4]的基础上,不仅考虑评分和信任的显式影响,还将用户的隐式反馈信息以及用户的隐式社交信息考虑到模型中,更加符合实际的社交网络情景。TBPR^[2]基于 EM 算法,通过推荐准确性对社交网络的强弱关系进行分类,为所有的用户和项目学习潜在的特征向量。DASO^[5]采用双向映射的方法,通过对抗学习在社交域和项目

域之间传递用户信息,最终优化用户和项目的表示。如图 1 所示,尽管用户在两个域中建立联系,但无法从社会结构中区分不同联系人的特定偏好。例如:李明喜欢听取赵鹏关于书籍方面的建议,但在音乐方面会虚心向王红请教。由此可知,社会关系中人们的不同偏好在一定程度上会对用户的行为产生影响。如何使用社会化推荐系统去解决上述问题,这需要我们深入研究。

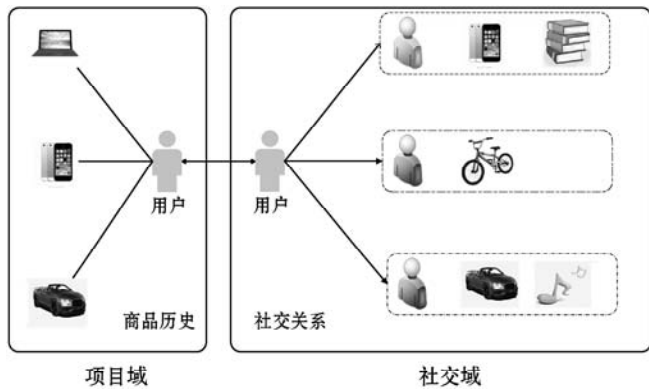


图 1 社会化推荐系统的结构

为了量化人们的不同偏好对用户行为产生的影响,本文综合考虑了上下文中各种不同的因素,从兴趣表示和社会结构两方面进行推断。社会结构可以表示为用户-用户二部图,利用深度学习技术很难精确地提取其图特征,而新兴的图神经网络技术^[6-8]可以有效地学习实体间复杂的关系。Kipf 等^[6]简化了频域卷积的定义,并提出了在空间域进行卷积运算的 GCN,其本质是迭代聚合邻居的过程。在这基础上,GCN 出现了许多变体。GraphSage^[7]从聚合邻居的操作出发,将 GCN 由全图训练的方式改造成以节点为中心的小批量训练方式。GAT^[8]通过注意力机制来对邻居节点做聚合操作,从而实现了针对不同邻居权重的自适应分配,进而提高了图神经网络模型的学习能力。最近,GCN 也在社会化推荐系统中进行了探索。SocialGCN^[9]在 CF 的基础上,利用 GCN 的优势来捕捉社交网络的特征,进而用于构建用户嵌入和项目嵌入的深层模型。本文基于上述研究,利用 GAT 学习社会结构,进一步提高推荐系统的性能。

本文提出一种基于图注意力对抗网络的社会化推荐系统,即 GAASR。为了更好地捕捉到用户的潜在偏好,在推荐系统上进行社会约束,使用对抗性网络实现社会正则化,对抗性网络同时考虑了社会结构和兴趣因素。为了使社会结构中的节点信息与拓扑结构能够进行有机结合,使用图注意力网络来学习用户的社交嵌入向量。此外,由于无法确定是社会影响力还是潜在兴趣对用户偏好的影响,对抗性网络可以把这两个

因素进行区分,从而实现推荐器与社交网络表示的有效结合。在对抗性网络中,为了避免兴趣空间的崩溃,使用上下文加权函数,从而使得进入兴趣空间有更多的选择范围。本文的主要贡献如下:

(1) 为了使社会影响力和潜在兴趣能在推荐系统中发挥最大作用,使用了对抗性网络模型。

(2) 设计一个独特的对抗网络框架,生成器模仿用户-项目交互的数据分布,利用变分编码器生成伪样本数据,鉴别器利用图注意力机制提取社会结构中用户的特征,并将它作为社交网络嵌入,来鉴别是真实样本数据还是伪样本数据。

(3) 在模型中使用 Hadamard 投影的方法,目的是在上下文加权函数中实现用户特征的低秩双线池化,从而有效地避免兴趣空间的崩溃。

1 相关工作

1.1 图神经网络在推荐系统中的应用

随着深度学习的发展,图神经网络越来越受到人们的关注,并在计算机视觉^[10]和自然语言处理领域^[11]带来了很大的提升。近年来,由于图神经网络能够有效地学习复杂的图数据,研究人员尝试将图神经网络技术运用到推荐系统中,试图提高推荐系统的性能,并取得了成功。GC-MC^[12]是一种用于推荐系统中矩阵补全任务的图自动编码器框架,该框架包括了用户和项目的辅助信息。PinSage^[13]有效结合随机游走和图卷积神经网络,捕获到了图结构特征以及节点的特征,以生成节点的嵌入表示。这些具有代表性的工作均表明将图神经网络运用到传统的推荐系统中,可以很好地提升推荐的性能。

由于社交网络可以看作为用户-用户交互图,所以将 GNN 应用到社会化推荐是顺其自然的事情。SocialGCN^[9]结合了 GCNs 在社交网络中建模扩散过程的优势和经典的基于潜在因素的模型来捕捉用户的偏好。DiffNet++^[14]在 DiffNet^[15]的基础上,在统一框架中对神经网络影响扩散和兴趣扩散进行建模。DICER^[16]利用感知图神经网络来学习图的特征信息,并从深层上下文中提取相关的信息。尽管这些工作是有效的,但是基本上未考虑社会正则化对推荐系统的影响,或者忽略了潜在兴趣与社会影响力之间的相互作用,从而导致推荐性能欠佳。

1.2 对抗训练在推荐系统中的应用

最近,对抗性学习^[17]在医疗人工智能、图像处理和计算机视觉等领域取得成功。对抗性学习的主要

思想是模拟极小极大博弈,生成器试图模仿真实的数据分布,鉴别器用来区分虚假的例子和真实的数据。IRGAN^[18]是第一个基于 GAN 的推荐系统模型,该模型将生成器和鉴别器统一起来,利用生成器来生成信息的负样本,利用鉴别器来区分负样本和正样本,动态调整输入的数据,同时两个模型可以相互促进提升的效果。受 IRGAN 的启发,GraphGAN^[19]引入了一种称为 graph softmax 的 softmax 替代方案,克服了传统的 softmax 函数的局限性,加速训练,提高计算的效率。Wang 等^[20]开发了一种基于生成对抗网络的自适应负采样框架来优化流媒体推荐模型,提高推荐性能。此外,Chae 等^[21]首次尝试用 GAN 直接学习用户简档而不是通过生成负样本来改进推荐模型。此外,Wang 等^[22]通过增强用户-项目之间的交互来改进协同过滤,从而发现 GAN 的新应用。

也有一些社会化推荐中应用了对抗训练,将项目域与社交域通过 GAN 联系起来。例如,DASO^[5]利用对抗学习动态生成负样本,学习两个域之间的双向映射,最终优化用户和项目的特征表示;RSGAN^[23]借助生成器和判别器之间的竞争,动态自适应地生成可靠的朋友,可以减缓显式社会关系的稀疏性和不可靠性问题,显著地提高社会化推荐的性能;ESRF^[24]结合对抗训练和 GCN 来克服社会化推荐系统中社会关系的内在问题;文献[25]提出了一个模块化的对抗框架,集成了先进的推荐体系结构和社交表示模型。然而,这些框架没有充分考虑邻居节点之间的差异,因此,本文引入 GAT 来解决这个问题。

2 相关定义

首先介绍本文的一些定义和符号,设 U 和 I 分别

表示用户集合和项目集合,我们根据用户的隐式反馈定义用户-项目的交互矩阵 $Z \in \mathbf{C}^{|U| \times |I|}$ 。此外,用户-用户之间的社交网络可以用矩阵 $N \in \mathbf{C}^{|U| \times |U|}$ 表示。通过学习潜在向量来表示每个用户的兴趣嵌入矩阵 $X \in \mathbf{R}^{|U| \times d_x}$ 和社交嵌入矩阵 $S \in \mathbf{R}^{|U| \times d_s}$ (X_u, S_u 表示用户 u 的行数; d_x, d_s 表示嵌入维度的大小)。给定任何用户嵌入矩阵 E ,我们可以利用式(1)来计算 E 的潜在空间的用户-用户相似度。

$$P_E(u, v) \propto \sigma(E_u \cdot E_v) \quad (1)$$

式中: u, v 指的是用户, $\sigma(x) = \frac{1}{1 + e^{-x}}$, 社交嵌入空间 S 和兴趣嵌入空间 X 分别对用户的社交邻域和项目交互进行建模,从而由式(1)得到不同的用户-用户相似度 P_s, P_x 。

为了实现兴趣空间 X 的社会正则化,需要在嵌入空间中引入合适的距离度量。考虑到任意距离度量 D_M 的度量空间 M 的嵌入。为了在度量 D_M 下传递结构,对于社交链接 $(u, v) \in N$,得到 $\|S_u - S_v\|_{D_M} \rightarrow 0$ 。为了防止在将 S 结构转换为 X 结构时,发生兴趣空间 X 的崩溃,通过为每个成对约束引入特定的转换,现在系统的形式变换为 $\|S_u - S_v\|_{D_M} \rightarrow w(u, v)$,这种增强的表达能力能够在兴趣空间 X 中进行非简并编码,同时通过 $w(u, v)$ 保留社会结构的上下文转换。

3 GAASR 模型

本节将介绍所提出的基于图注意力对抗网络的社会化推荐系统(GAASR)。该模型的结构如图 2 所示,它主要由生成器、鉴别器、Hadamard 投影、优化器、社交网络五部分组成。下面首先对 GAASR 的模型框架进行介绍,然后对各个组成部分进行详细说明。




图 2 基于图注意力对抗网络的社会化推荐系统(GAASR)模型框架

3.1 GAASR 模型框架

由于社交空间和兴趣空间的竞争关系,使用对抗性网络模型来实现社会正则化。GAN 的生成器使用变分编码器,它根据先验分布获得合成样本。鉴别器试图构造一个决策边界,来区分合成样本和真实样本。生成器通过训练来合成模拟目标样本的数据点,从而对目标分布进行编码。

生成器通过优化可微的连续目标 O_G 来学习用户的兴趣嵌入矩阵 \mathbf{X} ,并利用式(1)来生成用户-用户相似度 $P_X(u, v)$,通过在变分编码器上进行社会正则化来显示结果。另一方面,社交网络 \mathbf{N} 利用图自动编码器来学习潜在向量,并生成了目标用户-用户的相似度,我们将其表示为 $P_N(u, v)$ 。生成器必须模仿该相似度来规范兴趣嵌入空间 \mathbf{X} 。最后,鉴别器学习独立于社交空间 \mathbf{N} 的社交嵌入空间 \mathbf{S} 。鉴别器在社交嵌入空间中利用 GAT 来学习潜在向量,生成用户-用户相似度 $P_S(u, v)$,构造生成源 $P_X(u, v)$ 和目标 $P_N(u, v)$ 之间的连接,并试图使兴趣空间的结构学习社交空间的结构。

本文通过一种随机稳定的方法来表示生成源 P_X 和目标 P_N ,该方法从每个空间中抽取一定数目的用户样本对。 $P_S(u, v)$ 表示鉴别器中每个抽样用户对的似然,理想情况下,鉴别器从目标 P_N 采样的真实用户对分配较高的似然概率估计,而将较低的似然概率估计分配给从生成源 P_X 采样的伪样本对,生成器的目标是混淆鉴别器,即最大化预期的伪样本对似然为 $\mathbb{E}(P_S(u_-, v_-))$,得到的整体目标为 O :

$$O = \min_X \max_S (\mathbb{E}_{(u_+, v_+) \sim P_N} \log P_S(u_+, v_+) + b \cdot \mathbb{E}_{(u_-, v_-) \sim P_X} w(u_-, v_-) \log(1 - P_S(u_-, v_-))) \quad (2)$$

式中: b 是平衡参数,生成器 G 学习兴趣嵌入空间 \mathbf{X} ,为了使得兴趣嵌入空间 \mathbf{X} 的结构混淆鉴别器,所以最大化伪样本对似然概率估计 $\log P_S(u_-, v_-)$,相反,鉴别器试图最大化真实样本对似然概率估计 $\log P_S(u_+, v_+)$,并最小化伪样本似然概率估计 $\log P_S(u_-, v_-)$ 。期望值 $\mathbb{E}(u, v)$ 分别在伪样本对和真实样本对上求平均。为了避免兴趣空间崩溃,防止 P_X 中用户的结构接近 P_N ,使用了上下文加权函数 $w(u, v)$ 。式(2)中 $w(u_-, v_-) \log(1 - P_S(u_-, v_-))$ 是相对于 P_S 进行正则化,从而使 \mathbf{X} 的选择范围更广,模型的表现力更强。

3.2 GAASR 模型实现

为了更好地理解模型,下面对生成器 G 、Hadamard 投影、鉴别器 D ,以及这些模块的交替优化方法进行详细描述。

3.2.1 生成器

将对生成器的假设限制为最普遍的假设,也就是说, G 通过优化可区分的连续目标 O_G 来学习用户兴趣嵌入 \mathbf{X} 。本文模型框架在 VAE 上进行社交正则化,具体有以下两种样本对抽样生成方法:

(1) 伪样本对抽样:伪样本对 (u_-, v_-) 的抽样方法是先选择 u_- ,然后抽样 $v_- \propto P_X(u, v)$ 。对每个用户的样本进行分层,以便每个用户在用户集合 U 中至少出现 ϵ 对。

(2) 真实样本对抽样:真实样本对代表潜在的社交网络结构。通过将生成器嵌入替换为来自社交网络 \mathbf{N} 的图自动编码器嵌入,对它们进行类似于上述伪样本对的采样。

3.2.2 Hadamard 投影

为了很好地表示用户之间的同质性和异质性,使用了上下文特征之间的乘性交叉因子。在本模型中,可以使用兴趣嵌入 X_u 和 X_v 在恰当维度上的乘性因子来推断用户对之间的共同兴趣和差别。

针对这种转化,使用 Hadamard 投影方法^[26]来实现上下文权重函数 $w(u, v)$ 中用户特征的低秩双线性池化^[27]。双线性池化主要用于特征融合,对于从同一个样本提取出来的特征 u 和特征 v ,通过双线性池化得到两个特征融合后的向量,进而用来分类。学习获得了一个投影矩阵,对于样本对 (u, v) ,输入的投影矩阵可表示为:

$$X_u^i = X_u \odot P_i, X_v^i = X_v \odot P_i \quad (3)$$

式中:投影矩阵 $\mathbf{P} \in \mathbf{R}^{N \times d_w}$, d_w 指上下文用户的特征维数;投影矩阵中的每一行 P_i 表示用户上下文的唯一转换; \odot 表示矩阵对应位置元素相乘。

接下来,计算每个投影仪的关注度权重值,来衡量用户在投影纬度下的对齐程度。

$$a_n(u, v) = \frac{\exp(X_u^n \cdot X_v^n)}{\sum_{i=1}^N \exp(X_u^i \cdot X_v^i)} \quad (4)$$

式中:关注度权重值 $a_n(u, v)$ 的值越大,表明在投影纬度上的乘性交叉因子越强,用于分类越准确。计算对齐向量作为加权投影总和,计算式如下:

$$\mathbf{A}(u, v) = \sum_{n=1}^N a_n(u, v) P_n \quad (5)$$

式中:对齐向量 $\mathbf{A}(u, v)$ 表示用户对 (u, v) 之间的关系,然后通过单个反馈层将其转化为成对权重值 $w(u, v)$ 。

3.2.3 鉴别器

本文模型以 GAT 作为鉴别器,通过优化式(2)中的最小-最大化目标来学习社交嵌入表示 \mathbf{S} 。形式定

义如下:设任意节点 v_i 在第 l 层所对应的特征向量为 $\mathbf{h}_i, \mathbf{h}_i \in \mathbf{R}^{d^{(l)}}$, $d^{(l)}$ 表示节点的特征长度,经过一个注意力机制为核心的聚合操作之后,输出的是每个节点新的特征向量 $\mathbf{h}'_i, \mathbf{h}'_i \in \mathbf{R}^{d^{(l+1)}}$, $d^{(l+1)}$ 表示输出的特征向量的长度。这里将这个聚合操作称为图注意力层。假设中心节点为 v_i , 并设邻居节点 v_j 到 v_i 的权重系数为:

$$\mathbf{e}_{ij} = a(\mathbf{W}\mathbf{h}_i, \mathbf{W}\mathbf{h}_j) \quad (6)$$

式中: $\mathbf{W} \in \mathbf{R}^{d^{(l+1)} \times d^{(l)}}$ 是该层节点特征变换的权重参数; $a(\cdot)$ 是计算两个节点相关度的函数,为了计算简单,只计算一阶邻居内的节点 v_i 的权重系数,在 GAT 中,将节点本身也视为自己的邻居。 a 可以用向量内积来表示一种无参数形式的相关性计算 $\langle \mathbf{W}\mathbf{h}_i, \mathbf{W}\mathbf{h}_j \rangle$, 也可以表示为一种含参数形式的神经网络层,如果满足 $a: \mathbf{R}^{d^{(l+1)}} \times \mathbf{R}^{d^{(l+1)}} \rightarrow \mathbf{R}$, 就可以输出一个标量值表示二者的相关性。这里选择了一个单层的全连接层作为相关性函数,具体计算式如下:

$$\mathbf{e}_{ij} = \text{LeakyReLU}(\mathbf{a}^T[\mathbf{W}\mathbf{h}_i \parallel \mathbf{W}\mathbf{h}_j]) \quad (7)$$

式中:它的权重参数为 $\mathbf{a} \in \mathbf{R}^{2d^{(l+1)}}$, Leaky ReLU 作为激活函数。为了将权重合理地分配,使用 softmax 归一化对所有的邻居的相关性计算进行归一化处理:

$$\alpha_{ij} = \text{softmax}_j(\mathbf{e}_{ij}) = \frac{\exp(\mathbf{e}_{ij})}{\sum_{v_k \in \tilde{N}(v_i)} \exp(\mathbf{e}_{ik})} \quad (8)$$

式中: α_{ij} 指的是权重系数,所有邻居的相关性经过式(8)的处理,从而使得所有邻居的权重系数相加和为 1。将式(7)和式(8)相结合,可以得到权重系数的计算式:

$$\alpha_{ij} = \frac{\exp(\text{LeakyReLU}(\mathbf{a}^T[\mathbf{W}\mathbf{h}_i \parallel \mathbf{W}\mathbf{h}_j]))}{\sum_{v_k \in \tilde{N}(v_i)} \exp(\text{LeakyReLU}(\mathbf{a}^T[\mathbf{W}\mathbf{h}_i \parallel \mathbf{W}\mathbf{h}_j]))} \quad (9)$$

按照注意力机制加权求和的方法,结合式(9)得到的权重系数,可以获得节点 v_i 新的特征向量:

$$\mathbf{h}'_i = \sigma\left(\sum_{v_j \in \tilde{N}(v_i)} \alpha_{ij} \mathbf{W}\mathbf{h}_j\right) \quad (10)$$

模型的鉴别器中,输入的是社交网络 N 中用户节点的特征,在实验中使用 one-hot 编码特征输入矩阵 \mathbf{F} 。因此,根据式(1)得到 $P_S(u, v) = 1/(1 + e^{-S_u \cdot S_v})$, 其中 $S_u = \text{GAT}(\mathbf{h}'_u)$ 。

3.2.4 优化器

下面介绍一下生成器 G , Hadamard 投影、鉴别器 D 中每个模块的特定目标函数通过式(2)中分离出来的相关项来获得每个模块的优化目标。

(1) 生成器优化:生成器 G 通过优化 \mathcal{O}_G 来学习 \mathbf{X} 和相关参数 θ_G , 对抗项优化了 G 的伪样本的鉴别器似然。

$$\mathbf{X}, \theta_G = \arg \min_{\mathbf{X}, \phi} \left(\mathcal{O}_G + \frac{\lambda}{\epsilon} \sum_{\epsilon_-} w(u_-, v_-) \log(1 - P_S(u_-, v_-)) \right) \quad (11)$$

这里对抗项权重值 λ 指的是总体正则化的强度,生成器更新 \mathbf{X} 以增加生成具有较高上下文权重和鉴别器似然的伪样本对的可能性。

(2) 鉴别器优化:鉴别器 D 学习社交空间 \mathbf{S} 和相关参数 θ_D , 从而使真实样本对的似然值 P_S 最大化,并最小化从生成器的兴趣空间 \mathbf{X} 采样的伪样本对的相似度。

$$\mathbf{S}, \phi = \arg \min_{\mathbf{S}, \phi} \left(\frac{1}{\epsilon_+} \sum_{\epsilon_+} \log P_S(u_+, v_+) + \frac{b}{\epsilon} \sum_{\epsilon_-} w(u_-, v_-) \log(1 - P_S(u_-, v_-)) \right) \quad (12)$$

作为优化的结果,鉴别器逐渐学习从 P_X 和 P_N 的样本之间的差别。反过来,生成器 G 有选择性地嵌入社会结构,来生成更难的伪样本。在本文模型中,模型的表达取决于加权的上下文特征,这就对 P_X 和 P_N 有无限的选择范围进行了约束。

(3) Hadamard 投影优化:Hadamard 在保持 \mathbf{X} 和 \mathbf{S} 不变的前提下,如何确定样本配对的优先级,从而使 G 的损失值最小化,从而转化为以下目标:

$$P, \theta_w = \arg \min_{P, \theta_w} \left(\frac{\lambda}{\epsilon} \sum_{\epsilon_-} w(u_-, v_-) \log(1 - P_S(u_-, v_-)) \right) + \sum_{n=1}^N \|P_n\|_2 \quad (13)$$

这里使用了一个 Lasso (每个 P_n 是一个组) 正则化,避免了过度拟合和鼓励稀疏投影。

每个模块通过 Nadam 更新交替训练,保持其他两个模块恒定不变。

4 实验

本文实验的操作系统为 Linux, 采用 Python 3.6 版本,基于 TensorFlow version 1.14 实现本文的模型,并得益于 GPU 来加速模型的训练过程。

4.1 实验设置

4.1.1 数据集

在 Epinions、Ciao 和 Delicious 三个公开的数据集上对所有的模型进行评估。

(1) Epinions: Epinions 数据集含有较多的数据,对于社会化推荐系统很适用,它不仅包含用户对电影的评分,还包含用户之间的信任与不信任关系。

(2) Ciao: Ciao 数据集包含用户对购买 DVD 的评分、用户之间社交关系、DVD 类别的数据。

(3) Delicious: Delicious 数据集是一个在线书签系统,包含用户间的社交网络、书签和标签信息。

由于这三个数据集提供了用户对商品的评分,所有的数据经过预处理,将其转化为 1 作为隐式反馈。表 1 列汇总了这些数据集的细节。

表 1 评估数据集的详细信息

数据集	用户数目	项目数目	项目交互	社交链接
Epinions	7 317	104 975	283 319	111 781
Ciao	18 088	261 649	764 352	355 813
Delicious	1 521	1 202	8 397	10 401

4.1.2 对比模型

为了评估模型的推荐性能,将本文方法与以下基准方法进行比较。

(1) BPR^[28]:是所有隐式反馈推荐方法的基础模型。

(2) NCF^[29]:这是基于神经网络的协同过滤框架,该框架将矩阵分解和多层感知器模型相结合来学习用户与项目的交互功能,利用用户的历史反馈对项目进行排名。

(3) VAE-CF^[30]:该模型在图变分编码器的基础上用于对隐式反馈的数据进行协同过滤。

(4) SBPR^[31]:SBPR 将社交联系作为获得更准确的基于排名的模型,通过假设用户倾向于给他们的朋友更喜欢的项目分配更高的排名。

(5) SNCF:通过社会网络嵌入表示来修改 NCF,本文把这种变体称为 SNCF。

(6) SEREC^[32]:SEREC 利用社交信息来捕获用户暴露而不是用户的相似偏好,假设用户从他们接触的人那里获得商品的信息,其中一些商品会被购买。

(7) Asr-VAE^[25]:Asr-VAE 是一种利用对抗性框架,融合社会正则化项目的推荐框架。

为了评估本文模型的推荐性能,将与上述七组代表性模型进行比较。包括没有社交网络的推荐系统 BPR、NCF、VAE-CF,传统的社会化推荐系统 SBPR 和 SNCF,带有社交关系的曝光推荐系统 SEREC,以及基于深度神经网络的社会化推荐系统 Asr-VAE。

4.1.3 评价指标

为了评估所有推荐模型的性能,实验计算了 Recall@K 和 NDCG@K。其中 Recall@K 是指每个用户的前 K 个推荐中相关项目所占的比重,当 K 固定时,精确度仅由真阳性样本所决定,而召回率由真阳性和假阳性样本共同决定。NDCG 用作排序结果的评价指标,考虑理想情况下排名列表的顺序。Recall 定

义为:

$$R_{\text{recall@K}} = \frac{\sum_{i=1}^K r_{\text{el}_i}}{\min(K, |y_u^{\text{test}}|)} \quad (14)$$

式中: $r_{\text{el}_i} = 1/0$ 表示前 K 个推荐列表中排名第 i 的项目是否在测试集中; y_u^{test} 表示用户 u 在测试集中评分的项目数。NDCG 定义为:

$$N_{\text{DCG@K}} = \frac{D_{\text{CG@K}}}{I_{\text{DCG@K}}} \quad (15)$$

式中: $D_{\text{CG@K}}$ 和 $I_{\text{DCG@K}}$ 分别为:

$$D_{\text{CG@K}} = \sum_{i=1}^K \frac{2^{r_{\text{el}_i}} - 1}{\log_2(i + 1)} \quad (16)$$

$$I_{\text{DCG@K}} = \sum_{i=1}^{|R_{\text{EL}}|} \frac{2^{r_{\text{el}_i}} - 1}{\log_2(i + 1)} \quad (17)$$

式中: r_{el_i} 表示第 i 个位置时的等级相关性; $|R_{\text{EL}}|$ 表示按照相关性从大到小的顺序排序,取前 K 个组成的集合。

NDCG@K 和 Recall@K 的值越高,性能越好。在 $K=20,50$ 的情况下评估每个排名列表,如表 2、表 3 和表 4 所示。

表 2 推荐系统性能在 Epinions 的对比实验结果

方法	Epinions			
	R@20	R@50	N@20	N@50
BPR	0.264	0.440	0.141	0.176
NCF	0.310	0.462	0.138	0.181
VAE-CF	0.336	0.510	0.161	0.204
BPR	0.271	0.446	0.138	0.185
SNCF	0.306	0.468	0.189	0.202
SEREC	0.348	0.496	0.167	0.213
Asr-VAE	0.358	0.532	0.173	0.216
GAASR	0.370	0.546	0.181	0.232

表 3 推荐系统性能在 Ciao 的对比实验结果

方法	Ciao			
	R@20	R@50	N@20	N@50
BPR	0.232	0.428	0.128	0.162
NCF	0.282	0.471	0.147	0.193
VAE-CF	0.299	0.496	0.152	0.197
SBPR	0.217	0.439	0.140	0.174
SNCF	0.284	0.478	0.151	0.196
SEREC	0.303	0.513	0.158	0.202
Asr-VAE	0.312	0.528	0.138	0.196
GAASR	0.318	0.531	0.146	0.201

表 4 推荐系统性能在 Delicious 的对比实验结果

方法	Delicious			
	R@ 20	R@ 50	N@ 20	N@ 50
BPR	0.363	0.590	0.271	0.328
NCF	0.498	0.753	0.283	0.401
VAE-CF	0.585	0.771	0.327	0.416
SBPR	0.381	0.625	0.292	0.362
SNCF	0.520	0.747	0.296	0.380
SEREC	0.589	0.762	0.314	0.398
Asr-VAE	0.617	0.797	0.379	0.442
GAASR	0.636	0.807	0.431	0.453

4.1.4 参数设置

将用户-项目交互数据随机的 80% 作为训练集来学习参数,10% 作为验证集来调整参数,最后 10% 作为测试集来进行性能对比^[1]。本文使用的对比方法的代码都来自 Github,并且参数都是按照作者论文中所指定的,在本文数据集上获得实验结果。为了公平起见,将所有模型的表示维度设置为 128。对于本文模型,对于权重 λ 和平衡度 b 都在 $(0, 10]$ 范围内调整,将 hadamard 投影设置为 $N = 10$ 。

4.2 实验结果与分析

4.2.1 模型对比分析

在本文模型中,通过使用 Epinions、Ciao 和 Delicious 三个数据集进行分析实验。以 Delicious 数据集为例,它包括两部分:用户的评论记录(用户-项目二元组)和用户的社交关系(用户-用户二元组)。本文模型使用对抗网络来处理社交空间和兴趣空间的竞争关系,生成器使用变分编码器,它根据用户的评论记录获得合成样本;在模型的鉴别器中,使用 one-hot 编码来提取社交关系中用户节点的特征作为鉴别器的输入,利用图注意力机制获得社交网络嵌入矩阵,充分考虑邻居节点之间的差异,从而更好地鉴别了真实样本数据和伪样本数据,为提高推荐的准确性奠定了基础。此外,利用对抗网络将社会影响力和潜在兴趣进行分离,进而对模型的整体目标进行优化,最终实现推荐性能的提升。推荐系统性能对比的实验结果如表 2、表 3 和表 4 所示。

首先,利用社交网络信息的推荐系统通常比没有利用社交网络信息的传统推荐系统整体性能上表现得更好。例如,SBPR、SNCF 的性能分别优于 BPR、NCF,本文方法 GAASR 效果明显优于 BPR 与 NCF。在 Delicious 数据集上表现最为明显,GAASR 与传统的推荐系统整体上表现最好的模型 VAE-CF 相比,R@ 20、R@ 50 及 N@ 50 分别提升了 0.051、0.036 和 0.037,N@ 20 最为


明显,提升了 0.104。这些性能表现是在意料之中的,因为社交网络信息对传统的推荐系统起到辅助作用,对历史项目交互具有补充作用,因此能很好地帮助用户学习用户的偏好。

其次,GAASR 在三个数据集上的整体性能优于其他的推荐系统方法(最优值以粗体表示)。除了 Ciao 的 N@ 20 与 N@ 50 的方法外,GAASR 与其他基线相比,效果都有所提高。与其他基线相比,GAASR 在 Delicious 数据集上的性能具有显著的提升,即使与最好的基准方法 Asr-VAE 相比,R@ 20、R@ 50 及 N@ 50 分别提高了 0.019、0.010 和 0.011,而 N@ 20 提高了 0.052。整体而言,GAASR 超过了其他的基线,在 Epinions 数据集上的性能也有所提升。


最后,可以发现 GAASR 和 Asr-VAE、SEREC 明显高于以前的社会化推荐算法。SEREC 对暴露的项目设置不同的级别,但是 CB^[33] 灵活地将购买能力归因于一个属性(兴趣因素或者社会因素),而 Asr-VAE 归因于上下文因素。GAASR 不仅将购买能力归因于上文因素,而且巧妙地在社交嵌入部分引入图注意力机制。本文模型性能提升主要归因于对抗网络架构和基于图注意力网络的社交嵌入。

4.2.2 实验参数分析

通过实验来研究潜在因素大小 d 对验证集的影响。以 Delicious 数据集的度量标准 R@ 20 和 N@ 20 为例,结果如图 3 所示。对于 Delicious 数据集上的两个排名度量,本文模型优于其他具有不同 d 值的模型。可以得出,随着潜在维度的增加,可以捕捉到更多用户和项目的隐藏因子,这有利于 Top-K 的推荐,因为它具有更强的建模能力。



(a) Delicious 数据集的 RECALL@20 指标结果



(b) Delicious 数据集的 NDCG@20 指标结果

图 3 对比不同潜在嵌入维度 d 在验证集的实验结果

接下来,实验考察对抗项权重 λ 对推荐给用户的项目多样性的影响,如图 4 所示。在每个社交网络的 GAE 嵌入中应用 K-means 聚类,根据推荐多样性选择中位数的用户群,作为前 50 名推荐的并集。 λ 选项以评价指标 R@50 作为每个数据集的最佳 λ 设置。当 λ 变化时,通过所获得的最大并集的百分比来表示推荐多样性的变化(即推荐的多样性越低意味着较小的并集,因此百分比较低)。




图 4 对抗项权重值 λ 对推荐项目多样性的影响

4.2.3 消融实验

为了验证图注意力网络与对抗网络对 GAASR 模型架构的影响,本节设置以下变体进行对比实验。

(1) GAASR:本文提出的社会化推荐模型的整个版本,包括所有的组件。

(2) GASR:本文模型架构的一个变体,含有除了对抗网络的所有组件。

(3) GCASR:改变本文模型架构的对抗网络模块中的鉴别器,用单层图卷积神经网络代替图注意力网络,其他组件不变。

我们将 GASR 与 GCASR 和完整版本的 GAASR 在 Delicious 数据集上进行性能对比。相关实验设置如第 4.1.4 小节所述,图 5 显示了三种框架在 Delicious 数据集上迭代十次训练得到的性能评价的指标值。

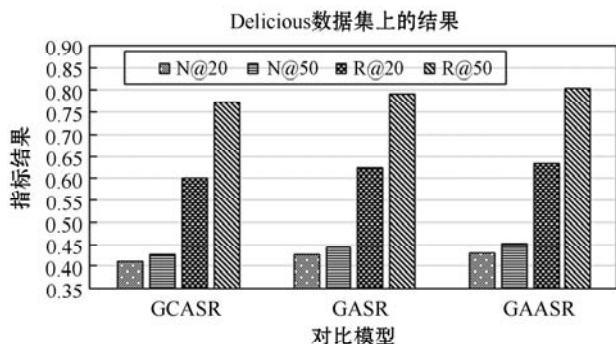


图 5 各种变体算法的性能

如图 5 所示,GAASR 的性能明显优于 GASR 和 GCASR,因此,每一个组件都对本文模型架构的整体性能作出了贡献。通过 GAASR 与 GCASR 进行比较,可

以得到,虽然 GCN 能够捕捉到社交图中隐藏的社交信息,但是 GAT 可以通过区分好友的重要性差异来进一步提高推荐系统的性能。GASR 的性能优于 GCASR,则证明了图注意力网络组件在本文模型架构中起到了关键作用。

5 结 语

本文提出一种基于图注意力对抗网络的社会化推荐模型(GAASR),该模型可以很好地将社交网络与推荐系统相结合。GAASR 模型利用对抗性网络架构,充分考虑了社会影响力与潜在兴趣对推荐系统的影响。再利用图注意力网络进行社交嵌入,为每个邻居节点分配更合适的权重,这大大提高了模型的性能。此外,为了充分考虑用户在不同上下文的喜好变化,使用 Hadamard 投影方法,可以有效地避免兴趣空间的崩溃。在三个真实数据集上验证了模型的性能,从它们的测试结果来看,本文方法具有一定的优势,确实可以提高推荐的精确度。

目前,本文模型仅考虑了本地邻居对用户的影响,未来还可以考虑高阶邻居对用户的影响。此外,项目域可以看作用户-项目异构图,将来还可以考虑将图神经网络应用到项目域,来更好地挖掘用户的潜在偏好,有望进一步提高推荐系统的性能。

参 考 文 献

- [1] Fan W, Ma Y, Li Q, et al. Graph neural networks for social recommendation[C]//The World Wide Web Conference, 2019:417-426.
- [2] Wang X, Lu W, Ester M, et al. Social recommendation with strong and weak ties[C]//25th ACM International on Conference on Information and Knowledge Management, 2016: 5-14.
- [3] Guo G, Zhang J, Yorke-Smith N. Trustsvd: Collaborative filtering with both the explicit and implicit influence of user trust and of item ratings[C]//AAAI Conference on Artificial Intelligence, 2015:123-129.
- [4] Koren Y. Factorization meets the neighborhood: A multifaceted collaborative filtering model[C]//4th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2008:426-434.
- [5] Fan W, Derr T, Ma Y, et al. Deep adversarial social recommendation[C]//28th International Joint Conference on Artificial Intelligence, 2019:1351-1357.
- [6] Kipf T, Welling M. Semi-supervised classification with

- graph convolutional networks[EB]. arXiv:1609.02907,2016.
- [7] Hamilton W, Ying R, Leskovec J. Inductive representation learning on large graphs[C]//31st International Conference on Neural Information Processing Systems,2017:1025 – 1035.
- [8] Veličković P, Cucurull G, Casanova A, et al. Graph attention networks[EB]. arXiv:1710.10903,2017.
- [9] Wu L, Sun P, Hong R, et al. SocialGCN: An efficient graph convolutional network based model for social recommendation[EB]. arXiv:1811.02815,2018.
- [10] 呼延康,樊鑫,余乐天,等. 图神经网络回归的人脸超分辨率重建[J]. 软件学报,2018,29(4):914 – 925.
- [11] Tai K, Socher R, Manning C, et al. Improved semantic representations from tree-structured long short-term memory networks[EB]. arXiv:1503.00075,2015.
- [12] Berg R, Kipf T, Welling M. Graph convolutional matrix completion[EB]. arXiv:1706.02263,2018.
- [13] Ying R, He R, Chen K, et al. Graph convolutional neural networks for web-scale recommender systems [C]//24th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining,2018:974 – 983.
- [14] Wu L, Li J, Sun P, et al. DiffNet++: A neural influence and interest diffusion network for social recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2020,34(10):4753 – 4766.
- [15] Wu L, Sun P, Fu Y, et al. A neural influence diffusion model for social recommendation [C]//42nd International ACM SIGIR Conference on Research and Development in Information Retrieval,2019:235 – 244.
- [16] Fu B, Zhang W, Hu G, et al. Dual side deep context-aware modulation for social recommendation[EB]. arXiv:2103.08976,2021.
- [17] 林嘉豪,章宗长,姜冲,等. 基于生成对抗网络的模仿学习综述[J]. 计算机学报,2020,43(2):326 – 351.
- [18] Wang J, Yu L, Zhang W, et al. IRGAN: A minimax game for unifying generative and discriminative information retrieval models [C]//40th International ACM SIGIR Conference on Research and Development in Information Retrieval, 2017:515 – 524.
- [19] Wang H, Wang J, Zhao M, et al. GraphGAN: Graph representation learning with generative adversarial nets[C]//32nd AAAI Conference on Artificial Intelligence and 30th Innovative Applications of Artificial Intelligence Conference and 8th AAAI Symposium on Educational Advances in Artificial, 2018:2508 – 2515.
- [20] Wang Q, Yin H, Hu Z, et al. Neural memory streaming recommender networks with adversarial training [C]//24th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining,2018:2467 – 2475.
- [21] Chae D, Kang J, Kim S, et al. CFGAN: A generic collaborative filtering framework based on generative adversarial networks[C]//27th ACM International Conference on Information and Knowledge Management,2018:137 – 146.
- [22] Wang Z, Gao M, Wang X, et al. A minimax game for generative and discriminative sample models for recommendation [C]//Pacific-Asia Conference on Knowledge Discovery and Data Mining,2019:420 – 431.
- [23] Yu J, Gao M, Yin H, et al. Generating reliable friends via adversarial training to improve social recommendation [C]//2019 IEEE International Conference on Data Mining,2019:768 – 777.
- [24] Yu J, Yin H, Li J, et al. Enhancing social recommendation with adversarial graph convolutional networks[EB]. arXiv:2004.02340,2020.
- [25] Krishnan A, Cheruvu H, Tao C, et al. A modular adversarial approach to social recommendation [C]//28th ACM International Conference on Information and Knowledge Management,2019:1753 – 1762.
- [26] Kim J, On K, Lim W, et al. Hadamard product for low-rank bilinear pooling[EB]. arXiv:1610.04325,2016.
- [27] Lin T, RoyChowdhury A, Maji S. Bilinear CNN models for fine-grained visual recognition [C]//2015 IEEE International Conference on Computer Vision,2015:1449 – 1457.
- [28] Rendle S, Freudenthaler C, Gantner Z, et al. BPR: Bayesian personalized ranking from implicit feedback [C]//25th Conference on Uncertainty in Artificial Intelligence, 2009:452 – 461.
- [29] He X, Liao L, Zhang H, et al. Neural collaborative filtering [C]//26th International Conference on World Wide Web, 2017:173 – 182.
- [30] Liang D, Krishnan R, Hoffman M, et al. Variational autoencoders for collaborative filtering [C]//2018 World Wide Web Conference,2018:689 – 698.
- [31] Zhao T, McAuley J, King I. Leveraging social connections to improve personalized ranking for collaborative filtering [C]//23rd ACM International Conference on Conference on Information and Knowledge Management,2014:261 – 270.
- [32] Wang M, Zheng X, Yang Y, et al. Collaborative filtering with social exposure: A modular approach to social recommendation [C]//32nd AAAI Conference on Artificial Intelligence,2018:2516 – 2523.
- [33] Wu Q, Zhang H, Gao X, et al. Dual graph attention networks for deep latent representation of multifaceted social effects in recommender systems [C]//the World Wide Web Conference,2019:2091 – 2102.