



研究与开发

## 基于图神经网络的权益推荐技术方案研究

陶涛, 李珍, 王冀彬, 徐海勇, 江勇, 陈卓, 张润波, 胡清源  
(中移动信息技术有限公司, 北京 100032)

**摘要:** 推荐系统是实现海量互联网权益产品智能化推荐的重要手段。为了提升个性化推荐的准确率, 提出了基于图计算方法的深度学习推荐系统。针对用户行为数据存在多源异质的特性, 基于深度学习图表示技术, 对用户多维特征及权益产品之间的多种交互方式进行图结构化信息抽取及异质图建模, 构建用户权益多元关系图谱, 实现了各类交互信息(如用户—App、App—套餐、用户—套餐)的有效聚合。通过构建异质图卷积神经网络, 学习各类异质性节点的高维特征向量, 挖掘用户潜在偏好行为, 提供具有较强可解释性的推荐链路, 进而大幅提升推荐成功率并产生经济价值。

**关键词:** 异质图; 图卷积神经网络; 权益推荐; 多源数据

中图分类号: TP399

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2023155

## Research on the graphical convolution neural network based benefits recommendation system strategy

TAO Tao, LI Zhen, WANG Jibin, XU Haiyong, JIANG Yong,  
CEHN Zhuo, ZHANG Runbo, HU Qingyuan  
China Mobile Information Technology Center, Beijing 100032, China

**Abstract:** The recommendation system is one of the important methods to realize the intelligent recommendation of massive Internet benefit products. In order to improve the accuracy of personalized benefits recommendation, a deep learning recommendation system based on graph computing method was proposed. Considering the heterogeneity of multi-source data, a graph representation technology based on deep learning was carried out to construct the multiple relationship graph between users and benefit products. The multiple relationship graph extracted the information of graph structure, and model the heterogeneous graphs for the multi-dimensional features of users and the multiple interaction modes between rights and interests products, which effectively aggregated various interactive information and the multiple feature. A heterogeneous graph convolutional neural network was built to learn the high-dimensional feature vectors for various nodes, and excavate users' latent preferences to provide a recommendation link with strong interpretability, which greatly improved the recommendation success rate and generating economic value.

**Key words:** heterogeneous graph, graph convolutional neural network, benefit recommendation, multi-source data



## 0 引言

随着移动互联网技术的飞速发展,我国形成了数量规模巨大的移动互联网用户群体,不同用户群体的服务需求偏好不断变化,整体呈现多元化、个性化、差异化趋势。为了更好地匹配用户需求,提升用户服务,权益市场也相应地进行匹配式多样化发展,产品类目显著增多。由于多数权益产品以人工化、定制化配置运营界面为主,用户须在省侧包装的个性化的非统一线上页面进行选择订购,难以及时有效地从海量权益产品中准确找到有付费意愿的权益,导致前端业务触点停留时间短、用户活跃度不足、付费率低。推荐系统(recommender system, RS)是解决上述信息超载问题的有效方法,它根据用户的多维行为特征进行信息抽取及个性化计算,将用户模型中兴趣需求信息与推荐对象模型中的特征信息匹配,同时使用相应的推荐算法进行计算筛选,从产品库中推荐用户可能感兴趣的产品,有效提高了信息资源的匹配度,大幅推动了经济效益的提升<sup>[1-2]</sup>。

传统的推荐系统主要基于用户的显式偏好与隐式偏好来制定推荐策略。显式偏好通过一种可以明确反映用户真实偏好的显示交互信号(如用户给出商品评分)得以表征,在与显式偏好相关的研究中,矩阵分解是经典的评分预测推荐模型<sup>[3]</sup>,该方法通过最小化均方误差来将用户—商品的交互矩阵分解为用户偏好矩阵与商品偏好矩阵。文献[4]进一步研究了多方面的用户偏好并设计了一种基于自适应注意力机制的协同过滤模型,可以有效融合客户偏好。针对显示偏好不足的问题,文献[6]将网络图中的各种关系信息与现有的用户反馈相结合,以提升推荐结果的质量。

尽管显式反馈信息(如用户打分、购买行为等)可以较为直接地反映用户偏好,但由于该类数据高度稀疏,给推荐系统的构建造成很大的挑战<sup>[7]</sup>。为了解决上述问题,研究人员对浏览、点

击以及相似群体的共享信息等隐式反馈行为进行研究,发现隐式反馈信号数据量更为丰富,且能在一定程度上反映用户的潜在偏好。现有研究中,以贝叶斯个性化排序为代表的 Top  $K$  算法通过学习用户的隐式偏好进行个性化推荐。文献[8]基于坐标下降方法,设计了  $k$ -separable 模型,可以高效地优化用户的隐式偏好。文献[9]提出了基于元素级交替最小二乘法(element-wise alternating least squares, eALS)的矩阵快速分解策略,实现对在线推荐系统中用户的隐式反馈进行实时建模。现有的针对隐式偏好的推荐系统可分为基于协同过滤(交互)的推荐系统<sup>[4-5]</sup>和基于内容(特征)的推荐系统,二者在为用户进行个性化推荐的过程中无法准确匹配用户的需求。而基于图计算的混合推荐系统(graph learning based recommender system, GLRS)将二者有效结合,并引入了多种辅助信息(图交互关系等)<sup>[9-10]</sup>,克服了“冷启动问题”,保证混合推荐系统在推荐初期也能有出色的表现。文献[11]考虑用户节点特征及本地邻域的影响,将用户和商品的交互连接进行推荐预测,但在该方法对邻域进行了平均分配。由于在实际应用中,邻域对用户的影响不尽相同,进一步地,文献[12]提出了多层次地图注意力网络,针对朋友关系、用户历史交互产品赋予不同的权值,从而有效提升了推荐的准确性。

在 GLRS 中,研究人员引入对关系数据具有一般性表示能力的图谱交互关系,采用学习图中的节点表示进行了大量的研究和应用,并将具有相同属性的物品节点通过边的低维特征表示进行连接,为下游数据挖掘任务生成更加丰富的特征,对交互系统中的复杂关联关系进行建模。推荐系统在在线用户进行交互的过程中,需要进行大量的在线数据训练,从而避免出现估计偏差问题。因此,将深度神经网络应用到图分析形成的图神经网络成为当前人工智能的热点<sup>[7, 10, 13-15]</sup>。随着图神经网络技术的快速发展,探索和利用图中的同

质或异质关系是构建高级推荐系统的一个前沿方向。然而,现有基于图神经网络构建的推荐系统仍面临一些挑战。例如,由于在运营商侧业务存在多阶包含关系,用户—商品图无法刻画用户—用户、用户—产品、产品—App等异质节点间的交互行为;用户在多类关系图(如用户—用户社交图、用户—商品图)中重复出现等。因此,与同质图不同,采用异质图能够考虑不同关系下节点的自信息与邻居信息的差异,有效解决属性异质图中结构复杂、属性丰富等问题,以满足当前多源用户交互数据刻画的应用需求。

某运营商用户关系数据除话单数据外,还包括脱敏后的权益数据、上网行为数据、家庭宽带数据、主副卡、亲情号、企业客户等用户数据,规模庞大、模态复杂,存在复杂的隐含关联。而现有的推荐机制主要针对离网风险高的用户进行优惠套餐推荐,未充分考虑用户的行为、偏好等信息,适用范围较小。为进一步提升经济效益,某运营商开发了以传统统计学习与机器学习为主的方法来进行推荐系统的研发,但目前该方法主要针对单一来源数据的分析,如使用 Logistic 回归、决策树等方法进行二元预测用户路径订购。该方法将用户多维属性特征与网络结构信息独立分析,无法深入挖掘多源数据之间的隐含关联,进而不能对节点类型、特征属性与网络结构信息进行有效融合,并导致给出的推荐结果缺乏可解释性,不能给出具体的推荐链路,影响了准确性分析。因此,现有的适用于运营商数据环境下的推荐算法存在较多不足,迫切需要提出一种融合关系型数据的图计算算法方案。

针对某运营商用户通话、交互数据规模巨大,且点边异质、套餐种类复杂多样的特点,本文设计了基于图计算的用户权益精准推荐方案,异质图建模流程如图1所示。模型基于脱敏后的位置、用户、订购、通话、社交、App浏览等信息,利用社交媒体应用积累的大量用户特征信息、行为记录等数据

(笔者使用的脱敏数据来源于某运营商省公司及专业公司(简称省专公司),省专公司均承诺数据在合法合规的前提下获得,拥有用户授权),进行用户在线行为建模,围绕用户将其属性、行为、关系以及订购权益等复杂多样的对象及其关系有效地关联组织起来,采用异质图进行建模,全面表示用户之间的交互关系。进一步地,本研究基于异质图卷积神经网络的表示学习技术与社交多模态数据分析技术,联合考虑社交媒体数据广泛存在的多模态信息内容,学习异质图中节点与边的表示方法,深度挖掘用户的潜在关联与喜好。基于以上研究,模型根据潜在的推荐链路计算用户—权益最佳推荐的元能力,从而为用户提供精准业务和产品推荐服务,实现用户偏好挖掘智能化、权益推荐精准化,进而大幅提升用户体验。




图1 异质图建模流程



## 1 异质图卷积神经网络模型

针对用户—套餐推荐问题,本研究的核心算法主要包括图结构数据抽取、异质图建模、图卷积神经网络操作、神经网络节点更新的特征表示等。

### 1.1 图结构数据抽取

为充分刻画用户偏好,针对全网用户套餐订购及使用的全量多源异构数据特性,本研究抽取了用户的归属省、服务基站与漫游基站等位置信息,年龄、职业、用户服务星级等身份信息,终端设备品牌与型号等设备信息,并分析了所处网域类别,如家庭网、校园网、集团网等重要信息,挖掘了用户的 App 使用行为信息,并对用户的权益套餐演变数据进行了时序抽取及更迭分析。此外,通过分析中国移动多源数据发现不同用户群体的兴趣偏好以及关注的事件具有明显差异,用户关注的信息、服务与用户的圈子息息相关,而每个用户同时处于公司、学校、行业等不同类别的圈子中,为了进一步提升多源数据应用的服务能力以及用户的使用体验,本研究进行用户好友圈划分识别,实现了用户社交网络的精准画像。

### 1.2 异质图建模

近年来,基于图卷积神经网络来进行图嵌入学习的方法受到广泛关注,本研究结合实际业务场景,提出了基于图卷积神经网络的动态异质图推荐算法,推荐流程如图 2 所示。

根据该流程图可以发现,在完成关系型数据的导入和清洗以后,需要分析数据表之间的关联信息,主要包含客观存在的关联、不同数据表之间的交叉而产生的关联行为。不同于传统的话费套餐业务,权益套餐推荐涉及多种用户潜在使用的 App 流量与话费套餐,如某运营商上架的随心系列权益产品内容,包括爱奇艺“星钻随心看”会员包(每月含爱奇艺星钻会员月卡及 30 GB 爱奇艺定向流量)、和平精英“随心玩”套餐(每月

含和平精英“吉利勋章”15 枚及 15 GB 和平精英定向流量)、饿了么“随心享”套餐(每月含饿了么会员月卡及 15 GB 优酷视频定向流量)等产品。因此,根据某运营商的权益套餐订购业务,主要抽取以下层面的多类关联行为。




图 2 推荐流程

#### (1) 用户和权益套餐的关联

由用户曾经购买过某权益套餐得出用户与该产品存在关联,同时根据用户购买权益套餐的时间划分时间片,作为此关联上的一个参数。

#### (2) 用户和 App 的关联

根据用户使用 App 的情况找到用户和 App 的关联,并且根据流量消耗情况确定用户和 App 的关联权重。

#### (3) App 和权益套餐的关联

每一个套餐产品中可能含有不同种类的 App,每种 App 所占比重也各有差异,因此可以根据用户所选套餐找到套餐产品和 App 的关联,并且根据 App 在套餐中的比重来确定权值。

由于异质图可以包含不同类型的对象,而对象间关系表示了不同的交互语义,因此异质图建模可以更加全面地表示系统的组成对象和它们之间的关系,产生更加有意义的信息。本算法通过构建异质图表示网络关系:针对抽取的所有关联,通过将每个用户、权益套餐和 App 都作为单独的节点,将抽取的关联信息作为两节点之间的边,

构建为异质图的边集,从而将全网客户的业务状态转为复杂网状结构,支撑对用户所有场景、实际、状态的映射。

### 1.3 图卷积神经网络操作

图结构型数据共包含  $N$  个节点,对每个节点的特征进行向量化处理,将所有节点的特征组成一个  $N \times D$  维的矩阵  $\mathbf{X}$ ,同时将各个节点之间的关系形成一个  $N \times N$  维的邻接矩阵  $\mathbf{A}$ 。 $\mathbf{X}$  和  $\mathbf{A}$  作为图神经网络模型的输入。

在图卷积神经网络模型中,层与层之间的传播方式设定为:

$$H^{(l+1)} = \sigma \left( \tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} H^{(l)} \mathbf{W}^{(l)} + \mathbf{b}^l \right) \quad (1)$$

其中,  $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}$ ,  $\mathbf{W}^{(l)}$  与  $\mathbf{b}^l$  分别表示第  $l$  层的权重与偏置,  $\mathbf{I}$  为单位矩阵,  $\tilde{\mathbf{D}}$  是  $\tilde{\mathbf{A}}$  的度矩阵,计算式为:

$$\tilde{D}_{ii} = \sum_j \tilde{A}_{ij} \quad (2)$$

$H$  是每一层的特征,对于输入层而言,  $H = \mathbf{X}$ ,而  $\sigma$  作为非线性激活函数,计算式为:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

由式(1)可知,与传统的神经网络不同,图卷积神经网络中的归一化图结构为  $\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}}$ 。采用传递方式能有效提取图的特征,原因分析如下。

矩阵  $\tilde{\mathbf{D}}$  与  $\tilde{\mathbf{D}}^{-\frac{1}{2}}$  均为对角矩阵,对邻接矩阵  $\mathbf{A}$  左乘  $\tilde{\mathbf{D}}^{-\frac{1}{2}}$  进行矩阵的行初等变换,并对  $\mathbf{A}$  右乘  $\tilde{\mathbf{D}}^{-\frac{1}{2}}$  进行列初等变换,则  $\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}}$  可以看作对  $A_{ij}$  进行了如下操作:

$$\tilde{A}_{ij} = \frac{A_{ij}}{\sqrt{D_{ii}} \sqrt{D_{jj}}} \quad (4)$$

因此,当一阶邻居顶点  $j$  的度很大时,信号在每次传播后根据衰减因子  $\frac{1}{\sqrt{D_{ii}} \sqrt{D_{jj}}}$  变小。该

算法原理类似于神经网络,若利用图进行卷积神经网络的训练,则需要加入可训练参数矩阵  $\mathbf{W}$  与截距  $\mathbf{b}$ ,通过激活函数即可得到每层的输出。

### 1.4 神经网络节点更新的特征表示

由于异质图中有 3 类节点的表示需要更新,而每类为多源异构数据,因此将每一类节点进行单独建模。

首先,需要对用户节点进行建模。对于用户节点来说,每一个用户由于使用了多个 App,所以与多个 App 具有边相连的关系,并且连接的边上都有一个消耗流量的权值。而每个用户又和多个套餐产品相连,根据购买套餐的时间,将时间的关联定义该相连边上。据此,用户建模模块如图 3 所示,其中 item 表示权益套餐, user 表示用户节点, App 模块表示权益套餐中链接的 App。




图3 用户建模模块

其次,对套餐产品进行建模。由于每一个套餐产品都被多个用户购买过,所以套餐产品与多个用户直接相连,连接的边上通过订购的时间长度来衡量权重。而每一个套餐产品又与多个 App 相连,用来表示套餐和 App 的包含关系,连接的边上通过所包含的 App 流量数来衡量一个权重。套餐建模模块如图 4 所示。




图4 套餐建模模块



最后, 对 App 模块进行建模。根据不同套餐中包含的不同类型的 App 来确定套餐与 App 的关联, 关联的权重定义为包含的数量。而根据用户对每个 App 的使用情况来确定 App 和用户的关联, 关联的权重以使用的总流量来衡量。App 建模模块如图 5 所示。




图 5 App 建模模块

在对节点的建模模块进行拆分以后, 下一步根据节点和边的信息, 进行邻居节点的聚合。

因为 App 节点不涉及最终相似度的评定, 因此先分析 App 节点的信息聚合 (App embedding)。App 节点聚合过程如图 6 所示。

由图 6 所示, 聚合 App 节点时, 需要根据邻居关系的抽取聚合当前 App 节点的用户邻居和套餐产品邻居。首先, 在聚合套餐邻居时, 针对每个 App 可能和多个套餐相连的现象, 采用边信息

中标记了套餐包含此 App 定向流量数值的带权边表示方法, 并以此来确定每个套餐邻居的权重比例, 进而在本算法使用该值来确定每个套餐邻居在聚合过程中所占据的比重。

在对边上的向量和用户向量进行整合后, 需通过多层感知器 (multiple layer perception, MLP) 确定套餐节点对 App 节点的影响, 根据向量  $x_{ia}$  求得效果  $f(x_{ia})$ , 计算式如下:

$$f(x_{ia}) = g([w \cdot x_{ia}] + b) \quad (5)$$

其中,  $g(\cdot)$  代表激活函数,  $w$  与  $b$  为神经网络的权重项与截距项。

然而在本研究中, 一个 App 可能对应多个套餐节点, 因此需要对这多个套餐进行池化处理。由于当前 App 对不同的套餐的决定程度不尽相同, 不能用平均值的方式来弱化受影响程度较强的套餐、强化受影响程度较弱的套餐。出于充分发挥边权重数值价值的考虑, 本算法使用注意力机制, 即: 重要的邻居权重重大, 不重要的邻居权重小。基于这种思想, 可以选择用 soft-max 函数。该函数多用于多分类问题中。

假设有一个数组  $V$ ,  $v_i$  表示  $V$  中的第  $i$  个元素, 那么这个元素的 soft-max 值为:




图 6 App 节点聚合过程

$$S_i = \frac{e^{V_i}}{\sum_j e^{V_j}} \quad (6)$$

对应到当前的场景中, 可以把不同套餐包含 App 的数值向量看作  $V$ , 每个向量可以进行取模操作, 也可以根据一层的 MLP 进行实数映射, 然后通过 soft-max 层来得到每一个套餐的权重, 也就是异质图上每一条边的权重记为  $\alpha_{ia}$ , 表示套餐产品  $i$  对 App 产品  $a$  的边的权值。通过综合向量  $x$  和权值  $a$ , 得到 App 聚合套餐节点信息的结果向量:

$$\alpha_{ia}^* = w_2^T \cdot \sigma(w_1 \cdot [x_{ia} \oplus p_i] + b_1) + b_2 \quad (7)$$

$$\alpha_{ia} = \frac{\exp(\alpha_{ia}^*)}{\sum_{a \in C(i)} \exp(\alpha_{ia}^*)} \quad (8)$$

$$h_i^I = \sigma \left( W \left( \sum_{a \in C(i)} \alpha_{ia} x_{ia} \right) + b \right) \quad (9)$$

其中,  $p_i$  表示当前 App 在聚合套餐信息后的向量表示。 $W$  和  $b$  表示神经网络中的权重和偏差,  $C(i)$  代表包含套餐  $i$  的集合。通过上述操作, 完

成了在 App 节点层面的套餐产品邻居聚合过程。

通过同样的方法, 根据不同用户的向量嵌入表示, 以及边上用户使用 App 消耗流量的数值, 可以把用户邻居进行聚合, 得到  $h_i^u$ , 表示 App 节点的用户邻居聚合结果。然后, 需要整合来自套餐空间的向量表示  $h_i^I$  和来自用户空间的向量表示  $h_i^u$ , 将整合后的向量通过 MLP 进行处理, 就可以得到 App 节点的嵌入表示。最后, 聚合用户节点和套餐产品节点。由于这两类节点需要参与到下游的相似度评估的任务中, 用户和套餐节点聚合过程如图 7 所示。

这两类节点的聚合过程整体和上述 App 节点的聚合过程类似。但由于用户对于套餐的订购行为有时效性, 是一个随着时间排序的序列, 序列前后存在或深或浅的依赖关系。随着时间推移, 用户可能会发生套餐的更换, 即在不同的时间下, 用户对套餐的喜好程度是不一样的, 基于这个前提, 考虑用户行为序列的演变规律, 本算法引入动态图的思想。

首先对整个时间段进行时间片的划分, 然后对每个时间片进行编号 (可以从 0 开始), 并使




图7 用户和套餐节点聚合过程



用用户订购套餐的订购时间所在时间片的数值对订购时间进行替代。在操作中通常取最后一个时间片作为推荐行为的时间基准，然后求出所有时间片距离最后一个时间片的时间间隔，最终以该时间间隔的倒数作为边上的衰减权重。通过上述处理，可以有效地使得早期订购信息影响力变小，而近期的订购信息的影响力变大。最终，可以得到最终的用户嵌入表示和权益套餐嵌入表示。

## 2 基于向量表示的权益推荐流程

通过构建异质图卷积神经网络模型，通过上文构建的图神经网络结构将用户、App、权益套餐等异质节点进行向量化表示，投射到同一空间进行相似度对比，从而选择合适的产品进行推荐。在本研究中，推荐流程主要包含利用损失函数进行模型参数寻优、相似度指标的构建并给出推荐链路等部分。

### 2.1 基于负采样的损失函数

由于在隐式反馈中，用于推荐的数据并没有具体的标签。因此，为了进行异质图神经网络模型的训练，一般假设用户订购过的商品为正例，并通过数据采样的方法，从用户未进行直接交互的产品集中选择一部分作为训练数据的负例，该操作称为负采样。通过正负采样的方法，构建了具有标签的数据集。

针对于本异质图卷积神经网络模型，采用的损失函数如下：

$$L = - \sum_{(u,v \in \Omega)} \ln \sigma(h_u \cdot h_v) - \sum_{(u',v' \in \Omega^-)} \ln \sigma(-h_{u'} \cdot h_{v'}) \quad (10)$$

其中， $\Omega$  表示正样本， $\Omega^-$  表示负样本，节点  $v$  与节点  $u$  实际相连，为邻居节点；而节点  $v'$  与节点  $u'$  通过负采样得到，即未进行交互。 $h_x$  代表元素  $x$  的向量表示，并使用  $\sigma(\cdot)$  Sigmoid 函数将二者的乘积进行转换。通过对损失函数进行模型优化，最终可以得到较优的用户和套餐节点的

向量表示。

### 2.2 设计相似度指标计算 TopN 推荐产品

在获得用户和权益套餐对应的向量表示后，该向量已经完全通过异质图神经网络框架融合了来自多跳邻居节点的相关信息。考虑推荐系统的思想是选择向量表示相近的元素进行匹配推荐，因此，为进一步计算用户和权益套餐的匹配程度，需要设计合理的节点间相似度指标。在本研究中采用向量点积相似度作为计算指标，具体的计算式如下：

$$\vec{a} \cdot \vec{b} = |\vec{a}| |\vec{b}| \cos \theta \quad (11)$$

其中， $\vec{a}$  与  $\vec{b}$  代表待对比相似度的两个向量，通过计算向量  $\vec{a}$  与  $\vec{b}$  的余弦相似度进行相似度计算。

通过计算点积相似度，对同一个用户与所有权益产品的点积结果进行降序排序，并取前  $n$  个权益套餐作为评测结果。在验证过程中，如若用户已经购买的权益套餐也在这  $n$  个权益套餐中，则可以认为本次推荐成功。

$$L = - \sum_{(u,v \in \Omega)} \ln \sigma(h_u \cdot h_v) - \sum_{(u',v' \in \Omega^-)} \ln \sigma(-h_{u'} \cdot h_{v'}) \quad (12)$$

### 2.3 根据元路径给出推荐理由

为了方便营销侧进行分析，对于每位用户推荐的每一个权益套餐，均需给出推荐理由，即当前用户是通过怎样的方式与目标权益套餐联系的。该目标映射到图网络中即找到一条当前用户到推荐权益套餐的一条元路径。区别于先前异质图表示学习方法只考虑元路径首尾节点的方式，本文保留中间节点的语义信息，并采用融合方式获得该元路径下的多个节点表示。

元路径计算逻辑如图 8 所示，给定图  $G=(\mathcal{A}, \mathcal{R})$ ，其中  $\mathcal{A}$  表示多类型异质节点（用户、权益、App 等）， $\mathcal{R}$  代表多种关联关系（产品订购、好友关系、App 使用等）。元路径代表了可达路径中的基础单元路径，即权益产品推荐结果






图8 元路径计算逻辑

中的具体有效逻辑,如用户1—用户2(用户1好友)—推荐产品,代表由于用户1与用户2存在着较强的交互关系,则可根据二者相似的偏好进行推荐产品的迁移。具体来说,元路径格式化的定义如下:

$$A_1 \xrightarrow{R_1} A_2 \xrightarrow{R_2} \cdots \xrightarrow{R_l} A_{l+1} \quad (13)$$

即式(13)描绘了从 $A_1$ 到 $A_{l+1}$ 的可达关系序列 $R_1 \circ R_2 \circ \cdots \circ R_l$ ,其中 $A_n$ 代表图中的节点, $R_n$ 代表路径 $A_n$ 到 $A_{n+1}$ 存在的关联关系。通过构建元路径,可以充分利用异构图中的节点与路径信息,使得推荐结果更具可解释性,便于验证推荐结果得正确性。

## 2.4 算法结果评测

为了客观地评测算法效果,在计算该指标时需要有一个离线的包含用户的历史行为记录的数据集。然后将该数据集通过时间分成训练集和测试集,通过在训练集上建立用户的行为和兴趣模型预测用户在测试集上的行为,并计算预测行为和测试集上实际行为的重合度作为预测准确度<sup>[16]</sup>。为了有效地评估算法方案,可使用TopN推荐预测准确度作为评测指标。

TopN推荐是一种网站为用户提供个性化推荐列表的推荐服务,其预测准确率一般通过准确率(precision)/召回率(recall)度量。令 $R(u)$ 是根据用户在训练集上的行为给用户做出的推荐列表,而 $T(u)$ 是用户在测试集上的行为列表。则推荐结果的准确率定义为:

$$\text{Precision} = \frac{\sum_{u \in U} |R(u) \cap T(u)|}{\sum_{u \in U} |R(u)|} \quad (14)$$

考虑在运营商中的主流算法为基于统计方法的机器学习算法,为了说明引入关系型网络分析能力、构建异质图神经网络的必要性,以及本研究方案在实际使用中的领先性,将此前投入一线生产运营的五大主流推荐算法与本算法进行对比。通过正负采样的方法构建了训练及验证数据集,利用在A省、B省收集的大规模脱敏数据集进行模型训练与测试集验证,具体的结果对比如图9所示。




图9 结果对比

从图9可以发现,传统的线性回归方式如Lasso、岭回归的模拟训练准确率在A省、B省较为相似,相比于其他算法处于较低水平。而SVM、决策树、XGBoost等算法由于采用了非线性模型结构,算法准确率有了一定的提升。以准确率效果更为突出的A省为例,SVM算法下的模拟准确率比岭回归算法下的准确率提升了0.19,此外,决策树与XGBoost算法的准确率进一步提高。而本文提出的GCN模型在A省、B省的算法准确率最高,分别为0.92与0.77。由此可见,相比于省公司使用的机器学习算法模型,本文方案通过构建异质图卷积神经网络,对多类型节点多跳间的特征及交互关系进行向量化表示,形成关系洞察能力,在大规模实际省用户数据集上能够显著提升推荐准确率,有更强的应用前景。因此,引入图神经网络等人



工智能算法,进行多维关系及高维特征的深度挖掘,是运营商未来进行深度数据分析及融合中的重点方向。

### 3 结束语

本研究通过对用户、权益套餐、App 等异质节点的分析,创新地将图关系作为推荐系统的辅助信息,构建了考虑交互系统中多元复杂关系的异质图卷积神经网络,同时引入动态建模思想和注意力机制,以提高动态建模的精准度和邻域聚合的偏好区分。通过学习图中节点和边的低维特征表示,为下游数据挖掘任务生成更加丰富的特征。本研究具有两大优势:一是关系丰富,能够有效地整合用户、产品、特征等多级异构关系于一体,尤其针对交互数据稀疏的场景,可以显著提升推荐准确性及鲁棒性;二是关系明确,由于图网络里将序列关系进行了显式构建,通过关系序列可以为推荐结果链路提供可解释性。

在未来的研究中,本方法还可以从以下 3 个方面进行扩充:首先,进一步考虑权益产品所涉及的知识类别,通过构建行业知识图谱,进行权益产品的关联构建;其次,由于用户行为模式随兴趣偏好的转移而不断变化从而导致异质图结构变更,拟研究多源数据异质图中的时空信息的建模方法,从而实现动态异质图数据的有效管理与分析;最后,开发异网用户识别功能,并设计个性化的推荐策略,借助权益推荐进行种子用户的有效营销,以提升营销推荐的业务价值。

(声明:本论文所涉内容仅是学术框架下的技术理论研究,未来在商业场景中应用会满足各项法律及行业要求。)

### 参考文献:

- [1] AGRIMA M, POOJA G, SHARMA A K, et al. A Study on recommender systems[J]. Smart and Sustainable Intelligent Systems, 2021.
- [2] SUN J N, ZHANG Y X, GUO W, et al. Neighbor interaction aware graph convolution networks for recommendation[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM Press, 2020: 1289-1298.
- [3] Curran Associates Inc. Probabilistic matrix factorization[R]. 2007.
- [4] CHENG Z Y, DING Y, HE X N, et al. A<sup>3</sup>NCF: an adaptive aspect attention model for rating prediction[C]//Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence. California: International Joint Conferences on Artificial Intelligence Organization, 2018.
- [5] 柯福顺, 姚晓辉. 基于多源数据融合的协同推荐方法[J]. 电信科学, 2015, 31(7): 86-89.  
KE F S, YAO X H. Collaborating filtering method based on multiple data sources[J]. Telecommunications Science, 2015, 31(7): 86-89.
- [6] YU X, REN X, SUN Y Z, et al. Recommendation in heterogeneous information networks with implicit user feedback[C]//Proceedings of the 7th ACM conference on Recommender systems. New York: ACM Press, 2013: 347-350.
- [7] 阳德青, 夏西, 叶琳, 等. 知识驱动的推荐系统:现状与展望[J]. 信息安全学报, 2021, 6(5): 35-51.  
YANG D Q, XIA X, YE L, et al. Knowledge-enhanced recommender systems: a survey and prospect[J]. Journal of Cyber Security, 2021, 6(5): 35-51.
- [8] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[J]. CoRR, 2016, abs/1609.02907.
- [9] HE X, ZHANG H, KAN M Y, et al. Fast matrix factorization for online recommendation with implicit feedback[EB]. 2017: arXiv: 1708.05024.
- [10] Curran Associates Inc. Reasoning with neural tensor networks for knowledge base completion[R]. 2013.
- [11] WU L, SUN P, FU Y, et al. A neural influence diffusion model for social recommendation[EB]. 2019: arXiv: 1904.10322.
- [12] WU L, LI J W, SUN P J, 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.
- [13] DEFFERRARD M, BRESSON X, VANDERGHEYNST P. Convolutional neural networks on graphs with fast localized

spectral filtering[J]. CoRR, 2016, abs/1606.09375.

- [14] HAMILTON W L, YING R, LESKOVEC J. Inductive representation learning on large graphs[EB]. 2017: arXiv: 1706.02216.
- [15] GORI M, MONFARDINI G, SCARSELLI F. A new model for learning in graph domains[C]//Proceedings of 2005 IEEE International Joint Conference on Neural Networks. Piscataway: IEEE Press, 2005: 729-734.
- [16] KUANR M, MOHAPATRA P. Assessment methods for evaluation of recommender systems: a survey[J]. Foundations of Computing and Decision Sciences, 2021, 46(4): 393-421.

## [作者简介]



**陶涛** (1972- ), 男, 博士, 中移动信息技术有限公司副总经理、高级工程师, 国务院政府特殊津贴获得者, 主要研究方向为大数据领域的架构、系统规划、技术创新、运营管理等。



**李珍** (1994- ), 女, 博士, 中移动信息技术有限公司大数据平台部工程师, 主要研究方向为多源数据融合、图计算等人工智能算法。



**王冀彬** (1980- ), 男, 中移动信息技术有限公司大数据事业部总经理、高级工程师, 主要研究方向为大数据与人工智能、数据资产及数据能力构建、数据服务和大数据生态建设等。



**徐海勇** (1970- ), 男, 中移动信息技术有限公司总经理、正高级工程师, 主要研究方向为移动通信、互联网、大数据。



**江勇** (1973- ), 男, 中移动信息技术有限公司大数据事业部副总经理、高级工程师, 主要研究方向为大数据与人工智能、多源数据融合、大数据产品及应用等。



**陈卓** (1983- ), 男, 中移动信息技术有限公司大数据平台部副总经理、高级工程师, 主要研究方向为大数据分布式计算、云原生大数据、海量数据处理和数据融合挖掘。



**张润波** (1989- ), 男, 现就职于中移动信息技术有限公司, 主要研究方向为机器学习、NLP、图数据库开发与应用、图计算、知识图谱等。



**胡清源** (1989- ), 男, 现就职于中移动信息技术有限公司大数据平台部, 主要研究方向为大数据中台能力、统筹全网数据管理、提升大数据治理技术等。