

# 基于联合复杂网络 Cn-RippleNet 模型的推荐方法

罗宇泰, 徐涛, 徐章博

(西北民族大学 中国民族语言文字信息技术教育部重点实验室, 甘肃 兰州 730030)

**摘要:** RippleNet 对用户偏好传播进行建模, 并运用在推荐系统中, 取得了良好的效果, 但 RippleNet 没有考虑知识图谱中的实体权重, 导致推荐的实体不够精确。提出了一种加入复杂网络节点影响力的 Cn-RippleNet 模型, 在构建基于知识图谱的复杂网络之后, 抽取其最大子网模型, 计算图谱网络中节点影响力, 并将其作为实体的权重添加至图谱实体中, 最终计算出推荐结果。实验结果表明, 该方法将 RippleNet 的 AUC 和 ACC 的值提高到了 93.0% 和 85.6%, 弥补了 RippleNet 没有考虑图谱实体影响力的问题, 使推荐结果更符合用户预期。

**关键词:** 知识图谱; 推荐系统; 复杂网络; 节点影响力; RippleNet

**中图分类号:** TP391

**文献标志码:** A

**文章编号:** 1000-2758(2021)05-1070-07

传统的推荐系统方法有基于协同过滤, 通过分析用户的历史交互数据, 猜测他们可能的共同爱好<sup>[1]</sup>。但是该方法有着冷启动和稀疏矩阵的问题。研究人员提出了许多解决方法, 譬如结合知识图谱、社会网络<sup>[2]</sup>, 通过融合侧面信息到矩阵中填补一定的数据空缺, 但还是有较大的局限性。

在推荐系统中, 基于知识图谱的推荐方法有基于嵌入的方法和基于路径的方法。2016年 Zhang 等人提出了协同知识库嵌入(CKE)方法, 他将协同过滤模型与嵌入结合<sup>[3]</sup>。2018年 Wang 等人提出的深度知识感知网络(DKN), 他将实体嵌入和词嵌入分为2个不同的频道, 设计1个CNN模型将其结合<sup>[4]</sup>。2014年 Yu 等人提出了异构信息网络方法<sup>[5]</sup>, 2017年 Zhao 等人提出了基于元图的推荐方法<sup>[6]</sup>。两者都是通过创建异构信息网络, 基于网络的潜在特征, 从中抽取元路径或者元图, 来代表用户和项目之间的关系。Wang 等人同时结合基于嵌入和路径的方法提出了 RippleNet<sup>[7]</sup>。Wang 模拟水波纹传播方式, 对用户偏好进行模拟, 得到了非常好的效果。但 RippleNet 没有考虑到限定域知识图谱中的实体权重, 导致该模型无法得到不同权重实体的

推荐结果, 没有将推荐重点放在重要程度较高的实体上, 从而降低了推荐准确度。

在复杂网络科学中, 国内外学者对节点传播能力的评估进行了大量研究, 目前常用的方法有度中心性<sup>[8]</sup>、介数中心性<sup>[9]</sup>、紧密度中心性<sup>[10]</sup>等。为了解决这个问题, 本文将运用复杂网络科学的方法, 把知识图谱中三元组的实体抽象为节点, 关系抽象为连边, 计算出复杂网络中实体的节点影响力, 并将其作为实体权重再放入 RippleNet 网络中进行计算。

## 1 联合复杂网络的 Cn-RippleNet 算法

### 1.1 构建基于知识图谱的复杂网络

本文使用 RippleNet 中的电影和书籍知识图谱<sup>[7]</sup>, 这个图谱数据文件是一个纯文本文件, 构成该文件的数据是实体——关系——实体的三元组。以电影知识图谱为例, 构建电影图谱复杂网络时, 将所有实体抽象为网络的节点, 实体之间的关系作为连边, 表示节点之间的关联。建立的电影图谱复

**收稿日期:** 2021-04-12    **基金项目:** 国家科技重大专项(2017YFB1002103)、甘肃省青年科技基金(21JR1RA211)、中央高校基本科研业务费专项资金项目(31920210017)、国家档案局科技项目(2021-X-56)与甘肃省档案科技项目(GS-2020-X-07)资助

**作者简介:** 罗宇泰(1996—), 西北民族大学硕士研究生, 主要从事自然语言处理、知识图谱研究。

**通信作者:** 徐涛(1986—), 西北民族大学副教授, 主要从事自然语言处理、知识图谱、信息检索研究。e-mail: alfredxly@163.com

杂网络是一种无向非加权网络,具有如下特征:

1) 网络规模巨大,包含 169 366 个节点和 333 543 条边,因此建立非加权网络以减少计算复杂度,便于特征分析。

2) 只描述实体与实体之间的关联及关联间的距离,忽略关系的方向。

因为以知识图谱构建的网络不一定是全连通网络,导致某些节点无法参与计算其节点影响力,所以需要消除冗余,计算出电影知识图谱的最大连通子网。这里本文使用了连红老师的基于集合运算的子网抽取算法(SNESO)<sup>[11]</sup>。该方法将电影知识图谱文件 Graph 作为输入,经过子网抽取算法得到其输出最大连通子网的节点集合 MaxSubNet。

算法过程如下:

1) 从电影知识图谱 Graph 中抽取 1 条拥有最大度值节点的三元组信息,将三元组中的 2 个实体作为中心节点,也就是作为最大连通子网的中心层 SubNet<sub>i</sub>(这时  $i=1$ ),将此中心层加入 MaxSubNet。

2) 寻找 SubNet<sub>i</sub> 集合的相邻节点,即遍历 Graph 中的三元组(head, relation, tail),判断其中的 head, tail 是否存在于 SubNet<sub>i</sub> 集合中。如果存在,则表示对应 head 或者 tail 是集合 SubNet<sub>i</sub> 的相邻节点,将这些相邻节点加进相邻节点集 NeighborsSet<sub>i</sub> 中。

3) 对比 NeighborsSet<sub>i</sub> 集和 MaxSubNet 集,查看 NeighborsSet<sub>i</sub> 中是否有新的节点并不存在于 MaxSubNet 集中,如果存在这样的节点,则将 NeighborsSet<sub>i</sub> 并入 MaxSubNet。并将 SubNet<sub>i</sub> 用 NeighborsSet<sub>i</sub> 与 MaxSubNet 的差集替换掉,作为新的 SubNet<sub>i</sub>,  $i=i+1$ 。跳转到步骤 2)。如果不存在新的节点,则进行步骤 4)。

4) 返回 MaxSubNet。

此算法的关键步骤是对 Graph 三元组的遍历。从中心层出发,每一次的遍历 Graph,都会得到当前层节点的所有相邻节点。由于度值较大的节点存在于最大连通子网的概率更高,因此从度值最大的节点入手,找到最大连通子网的概率更高。

找到最大连通子网的所有实体,即 MaxSubNet 之后,再根据 MaxSubNet 从电影知识图谱文件 Graph 中提取出最大子网的边的集合,并且存储在 GraphLink 中,最后由 MaxSubNet 和 GraphLink 生成如图 1 所示结构的最大连通子网,存储格式依然是三元组形式。可以看见,中心层是由 2 个点构成,层

层扩散,2 个点的相邻实体作为第二层,第二层的相邻实体作为第三层,层层递归得到整个子网,直到没有新的相邻实体为止。

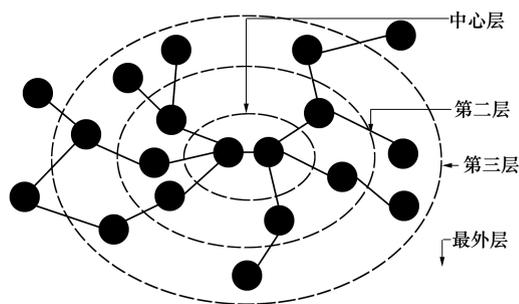


图 1 最大连通子网的模型结构

## 1.2 节点影响力计算

节点影响力是指在复杂网络中对所有节点进行建模分析,对网络中具有影响力或重要的节点进行排序。一个复杂网络通常包含有重要节点,并且少部分重要节点一般都能影响网络中的大部分节点。在不同网络中,研究人员都会从不同尺度、方向和实验条件下建立节点影响力的测量指标,并尽量用最精确和快速的方式找到最有影响力的节点,并对其进行排序<sup>[12]</sup>。

本文用已构建的最大连通子网作为一个复杂网络,对所有三元组的节点进行影响力计算。本文分别使用使用度中心性方法<sup>[8]</sup>介数中心性<sup>[9]</sup>、紧密度中心性<sup>[10]</sup>对电影知识图谱网络的节点影响力进行计算,寻找电影知识图谱中相对影响力较大的节点,并从实验结果中分析哪种方法更加有效。

在度中心性中,节点的度值是指连接某节点的其他节点的数量。度中心性则是根据单个节点度值大小和节点的总数来计算,节点度值越大,则度中心性也越大。在限定域知识图谱中,大多数网络的度分布为幂律分布,所以少数节点的度值较大,而大量的节点度值较小。因此,使用度中心性进行节点影响力计算,能够准确区分不同度值的节点,并赋予差异较大的权重。

由于以电影知识图谱构成的网络为无向网络,因此具体计算公式如下

$$C_D(N_i) = \frac{\sum_{j=1}^g x_{ij}(i \neq j)}{g-1} \quad (1)$$

在总数  $g$  为的节点所构成的无向网络中,单个节点  $i$  的度中心性使用  $C_D(N_i)$  表示。最终得到的结

果是一个比例,范围在 0.0 ~ 1.0 之间。0.0 表示其与任何一个节点都没有关系,1.0 表示与每一个节点都有直接关系。计算出知识图谱网络中所有节点的度中心性后,将其对应图谱中的实体上,采用字典存取方式保存,记为  $C$ 。介数中心性和紧密度中心性的保存方法同上。

### 1.3 联合复杂网络 Cn-RippleNet 模型

RippleNet 是模拟水波纹的传播方式,以用户点击历史为种子,并在限定域知识图谱上使用种子为初始点向外一圈一圈地扩散开来,这个过程称为用户的偏好传播。该模型认为种子外圈的项目依然属

于用户的潜在偏好,因此在刻画时也要将其考虑。以下是对 RippleNet 模型进行改进的地方:

Cn-RippleNet 的整体框架如图 2 所示,通过上部分实验得到当前 Hop 的 Ripple set 三元组中头部 head 的度中心性,且作为对应 head 的权值。然后在对 Ripple set 进行 embedding 时,将 Ripple set 的嵌入矩阵与 head 对应的权值矩阵中对应元素各自相乘,得到带有权重的 Ripple set embedding。之后按照 RippleNet 模型进行用户 embedding 和项目 embedding 计算,根据 Hop 次数进行偏好传播的迭代,最终得到带有实体权重的最终结果。

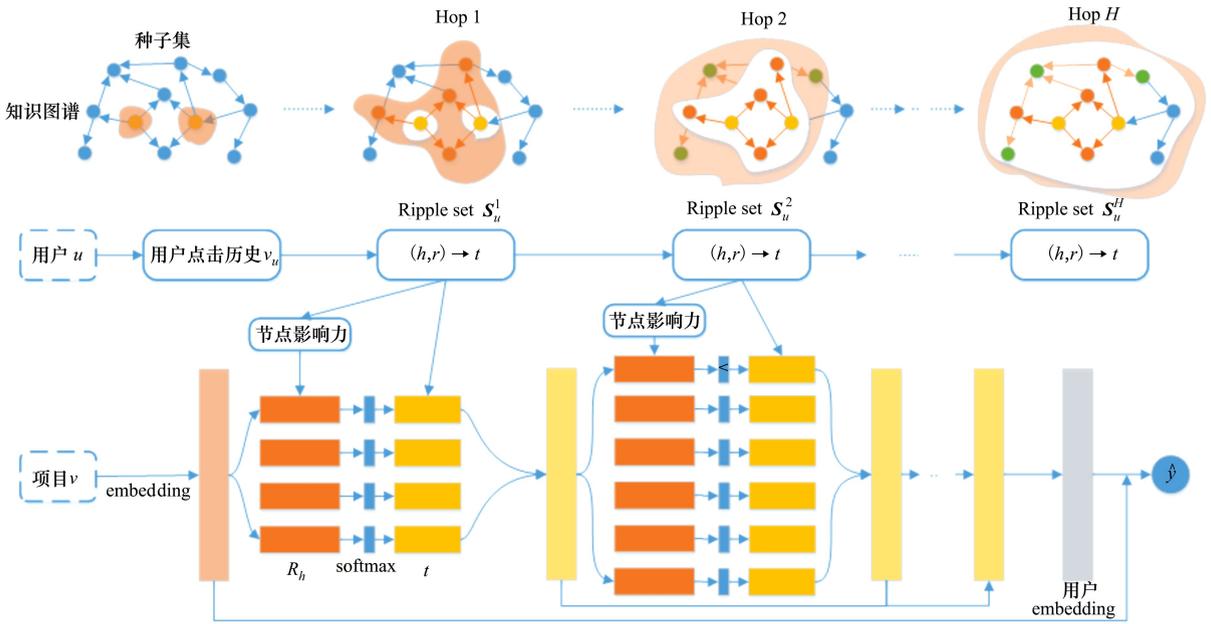


图 2 联合复杂网络 Cn-RippleNet 模型

Cn-RippleNet 是模拟水波纹的传播方式,以用户点击历史为种子,模拟偏好传播,对用户偏好节点添加影响力,再将其作为用户 embedding 与项目 embedding 进行计算。在整个 Cn-RippleNet 模型中,把用户  $u$  和项目  $v$  分别作为模型的输入,把用户  $u$  可能会点击项目  $v$  的预测概率作为最终输出。每一个用户  $u$ ,都会根据其点击历史  $v_u$  构建属于他的 Ripple set,其点击历史作为偏好传播的种子。然后沿知识图谱的关系向外扩充形成对应 Hop 的 Ripple set  $S_u^k (k = 1, 2, \dots, H)$ 。Ripple set  $S_u^k$  是用户点击历史  $v_u$  进行偏好传播后的三元组。Ripple set 与项目 embedding 交互,将用户  $u$  与项目  $v$  的信息相融合,然后将这些信息组合起来形成最终的用户

embedding。最后,使用用户  $u$  和项目  $v$  的 embedding 来计算最终的预测概率  $\hat{y}_{uv}$ 。

首先,在知识图谱中表示用户历史点击数据  $v_u$ ,由此来表示基于用户历史  $v_u$  的偏好相关实体,在 RippleNet 中,通过循环递归的方法,为用户  $u$  创建了偏好相关实体集,如下所示

$$\sigma_u^k = \{t \mid (h, r, t) \in \mathcal{D}, h \in \sigma_u^{k-1}\}, k = 1, 2, \dots, H \tag{2}$$

这些实体可被视为用户在知识图谱中依据历史点击  $v_u$  的偏好扩展。在给出相关实体的定义后,本文定义用户  $u$  所有的  $K$ -hop Ripple set 如下

$$S_u^k = \{(h, r, t) \mid (h, r, t) \in \mathcal{D}, h \in \sigma_u^{k-1}\}, k = 1, 2, \dots, H \tag{3}$$

在每一次 Hop 中,都会将 Ripple set 中头实体的度中心性  $C_i$  作为权值与 Ripple set 的嵌入矩阵  $e_i$  进行矩阵对应项乘积运算,得到带有权重的  $h_i$ 。如下所示

$$h_i = e_i C_i \quad (4)$$

之后将项目  $v$  的项目 embedding 和用户  $u$  的 Ripple set  $S_u^1$  进行计算。项目  $v$  分别与  $S_u^1$  中的头部  $h_i$  和关系  $r_i$  计算每个三元组  $(h_i, r_i, t_i)$  的相关概率  $p_i$

$$p_i = \text{softmax}(\mathbf{v}^T R_i H_i) = \frac{\exp(\mathbf{v}^T R_i h_i)}{\sum_{(h,r,t) \in S_u^1} \exp(\mathbf{v}^T R h)} \quad (5)$$

相关概率可以看做项目  $\mathbf{v}$  和头实体  $h_i$  在关系空间中  $R_i$  的测度。因为不同种类的关系类型肯定会计算出不同相似性,所以关系数据  $R_i$  也参与了相关概率的计算。获得相关概率后,将  $S_u^1$  中的所有尾实体  $t_i$  乘以相应的相关概率,并且返回向量  $\mathbf{o}_u^1$ 。 $\mathbf{o}_u^1$  可以看作是用户  $u$  对项目历史点击记录的第一次响应,用来组成用户  $u$  的 embedding。

$$\mathbf{o}_u^1 = \sum_{(h_i, r_i, t_i) \in S_u^1} p_i t_i \quad (6)$$

$$\mathbf{U} = \mathbf{o}_u^1 + \mathbf{o}_u^2 + \dots + \mathbf{o}_u^H \quad (7)$$

最后,结合用户 embedding 和项目 embedding,输出预测的点击概率

$$\hat{y}_{uv} = \frac{1}{1 + \exp(\mathbf{U}^T \mathbf{v})} \quad (8)$$

## 2 实验设置及结果分析

### 2.1 数据集

在本文的实验中,利用以下 2 个数据集进行实验:MovieLens-1M 和 Book-Crossing 分别是在电影推荐和图书推荐中经常用到的数据集。其中电影数据集 MovieLens-1M 包含网站上真实用户的上百万个评分。Book-Crossing 同样也包含百万本图书,并且所有图书都在图书交流社区中获得用户的评分。本文采用 RippleNet 模型中为每个数据集所构造的知识图谱。

表 1 2 个数据集的基本统计

| 数据集结构      | MovieLens-1M | Book-Crossing |
|------------|--------------|---------------|
| 用户         | 6 036        | 17 860        |
| 项目         | 2 445        | 14 967        |
| 关系交互       | 753 772      | 139 746       |
| 1-Hop 的三元组 | 20 782       | 19 876        |
| 2-Hop 的三元组 | 178 049      | 65 360        |

### 2.2 实验环境

表 2 中给出了 Cn-RippleNet 模型完整的参数设置,其中  $d$  表示项目和知识图的嵌入维数, $H$  表示 Hop 的次数, $l$  表示学习率。

本文将分别对每个数据集进行处理,将整个数据集分为训练集、评估集和测试集 3 个部分。数据占比为 6 : 2 : 2。每个数据集进行 5 次实验,并以其平均值作为最终结果。

表 2 Cn-RippleNet 模型的超参数

| 数据集           | $d$ | $H$ | $\lambda_1$ | $\lambda_2$ | $l$   |
|---------------|-----|-----|-------------|-------------|-------|
| MovieLens-1M  | 16  | 2   | $10^{-7}$   | 0.01        | 0.02  |
| Book-Crossing | 4   | 3   | $10^{-5}$   | 0.01        | 0.001 |

### 2.3 评价指标

本文使用 ACC (Accuracy) 和 AUC (Area Under Curve) 作为实验的评价指标。AUC 来源于 ROC,也就是 ROC 曲线图下半部分的面积。其值小于 1。ROC 曲线图用来判断二值分类器的优劣,得到的曲线图横坐标为 FPR (false positive rate),纵坐标为 TPR (true positive rate),将这些坐标对连接起来就形成了 ROC 曲线图。最后计算 AUC 面积得到一个 0.5~1 的值,AUC 越大分类效果就越好。

### 2.4 实验结果

本文构建了电影和书籍的知识图谱,使用基于集合运算的子网抽取算法构建了复杂网络。下图是最大联通子网的部分三元组数据。head 表示头,rel 表示关系,tail 表示尾。为方便使用和统计,实体和关系都使用序号来表示。

表 3 最大联通子网的部分数据

| head   | rel | tail   |
|--------|-----|--------|
| 49 695 | 4   | 73 697 |
| 36 508 | 9   | 9 892  |
| 34 029 | 4   | 73 698 |
| 73 699 | 9   | 73 700 |
| 6 511  | 1   | 57 474 |
| 4 159  | 4   | 73 701 |
| 73 702 | 2   | 2 466  |

通过对节点影响力的计算,得到了子网中每一个实体的度中心性。部分电影知识图谱实体的度中心性结果如下:

表 4 最大连通子网的部分度中心性

| 实体      | 度中心性          |
|---------|---------------|
| 2 458   | 0.216 795 780 |
| 2 755   | 0.100 912 037 |
| 36 906  | 0.000 137 355 |
| 52 673  | 0.000 005 494 |
| 73 289  | 0.000 038 459 |
| 74 102  | 0.000 009 884 |
| 144 090 | 0.000 027 471 |

表 5 不同模型的 AUC 和 ACC 的结果

| Model         | MovieLens-1M |       | Book-Crossing |       |
|---------------|--------------|-------|---------------|-------|
|               | AUC          | ACC   | AUC           | ACC   |
| Cn-RippleNet  | 0.930        | 0.856 | 0.755         | 0.691 |
| RippleNet     | 0.911        | 0.834 | 0.721         | 0.661 |
| CKE           | 0.796        | 0.739 | 0.674         | 0.635 |
| SHINE         | 0.778        | 0.732 | 0.668         | 0.631 |
| DKN           | 0.655        | 0.589 | 0.621         | 0.598 |
| PER           | 0.712        | 0.667 | 0.623         | 0.588 |
| SSP-RippleNet | 0.902        | 0.812 | 0.713         | 0.642 |

本文测试了不同参数时得到的结果, Cn-RippleNet 模型在参数  $d = 16, l = 0.02, \lambda_2 = 0.02$  的时候表现最佳, 得到的 AUC 和 ACC 都取得令人满意的结果。如表 5 所示, 相比其他主流基于知识图谱的推荐模型, Cn-RippleNet 在 2 个数据集上都取得了最好的性能。其原因在于 Cn-RippleNet 是将基于路径和基于嵌入的方法相结合, 利用知识图谱的侧面信息和节点影响力, 且对网络中的实体赋予了权重, 能够给予推荐系统更好的推荐, 得到更加准确的推荐结果。

通过表 5 的结果可以发现, 对比 CKE 的表现来看, Cn-RippleNet 在 AUC 和 ACC 的评价指标下分别高出了 13 个百分点和 12 个百分点, 这是因为 CKE 是将知识图谱同协同过滤方法融合, 只是利用了图谱的结构知识特征, 没有考虑图谱的路径。DKN 在电影和图书推荐方面表现不尽人意, 被 Cn-RippleNet 模型分别高出 28 个百分点和 26 个百分点。这是因为 DKN 更注重文本内容, 需要有多个实体才能保证预测的准确率。对 DKN 来说数据集的

实体名字不够长, 就无法提供有用的信息, 得到的结果也更加不准确。Cn-RippleNet 通过结合基于路径的方法, 得到了节点影响力克服了这个问题, 因此 Cn-RippleNet 也能在数据长度不够的情况下达到高性能。由于用户定义的元路径很难是最佳的, 所以 PER 在电影和书籍改编上的表现并不令人满意, 而 Cn-RippleNet 融合知识图谱实体的路径, 达到了更高的性能。在这 2 个数据集中, Cn-RippleNet 的性能最好。对比 RippleNet, 在 MovieLens-1M 数据集中, 改进后的 Cn-RippleNet 在 AUC 和 ACC 的评价指标下都高出了 1 个百分点, 而在 Book-Crossing 数据集中, 指标高出了 2 个百分点。这表明考虑节点影响力后的 RippleNet 的推荐效果更加准确。因此本文认为 Cn-RippleNet 在依据路径融合节点影响力的方法后效果更好。

在实验时, 考虑到 RippleNet 和 Cn-RippleNet 可能由于模型超参数的不同导致实验结果不严谨, 因此本文将添加 1 组对照试验, 将 2 个模型的超参数按照表 2 设置, 并将 RippleNet 的实验结果记为 SSP-RippleNet。通过表 5 的结果, 发现在相同超参数下, Cn-RippleNet 对比 SSP-RippleNet 的结果依然更优。在 MovieLens-1M 数据集中, AUC 和 ACC 的指标分别高数 3 个百分点和 4 个百分点, 而 Book-Crossing 数据集中, AUC 和 ACC 分别高出 4 个百分点和 5 个百分点。对比相同超参数的 RippleNet 模型, Cn-RippleNet 依然能够取得更好的结果。

同时由图 3 可以看出, Hop 的值在 2 或者 3 时, 效果最佳, 说明 Hop 数对与性能的影响并不是越高越好。从图 4 可以看出, 同样 Dim 也不是值越高效果越好, Dim 在 16 时模型性能最优。表 6 可以看出在这 2 个数据集下, 在度中心性、介数中心性、接近中心性的实验对比中, 度中心性的各项结果都优于其他。这表明在确定权重的方法中, 度中心性是最能体现 2 个数据集中网络节点的重要程度。因此对节点影响力的评价选择, 需要根据具体网络具体分析, 并且要通过实验来确定。

表 6 不同中心性的 AUC 和 ACC 的结果

| Node influence         | MovieLens-1M |       | Book-Crossing |       |
|------------------------|--------------|-------|---------------|-------|
|                        | AUC          | ACC   | AUC           | ACC   |
| Degree Centrality      | 0.930        | 0.856 | 0.755         | 0.691 |
| Betweenness Centrality | 0.891        | 0.824 | 0.721         | 0.651 |
| closeness centrality   | 0.916        | 0.839 | 0.744         | 0.665 |

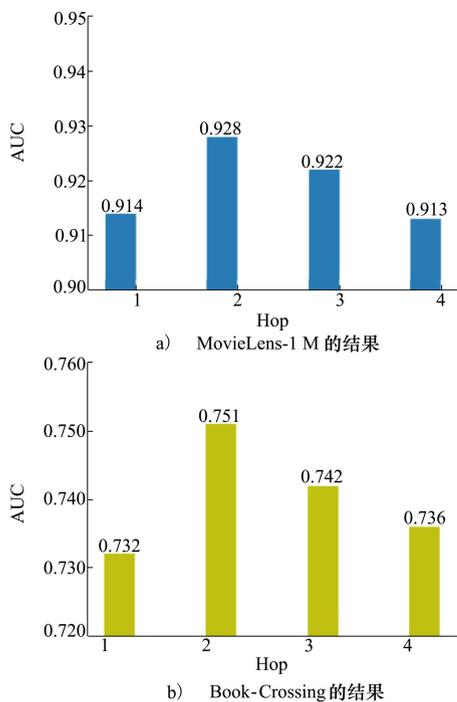


图 3 不同 Hop 的 AUC 值

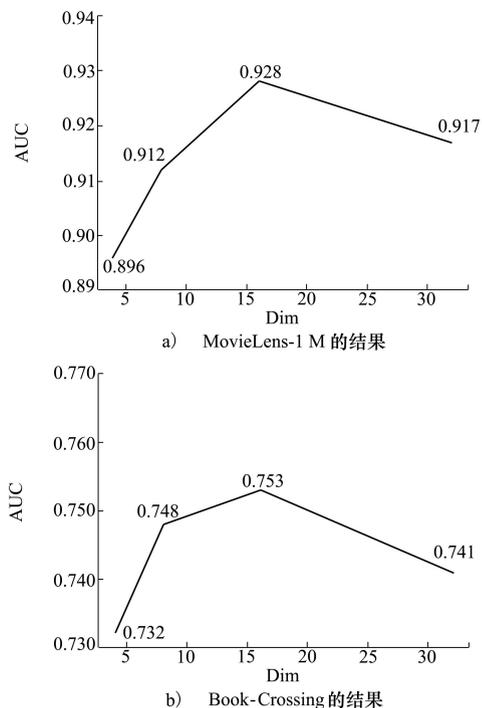


图 4 不同 Dim 下的 AUC 值

### 3 结 论

本文提出了一种融合复杂网络节点影响力的 Cn-RippleNet 推荐模型。对领域知识图谱进行了网络化,计算了知识图谱中实体的影响力,并将其融入知识图谱的网络中,使得推荐结果更加符合人们的

偏好,解决了 RippleNet 没考虑关键节点对推荐结果的影响的问题,从而增加了推荐精度。实验表明,通过节点影响力改进的 Cn-RippleNet 算法能够提高推荐算法的结果。下一步可以考虑将知识图谱的最大联通子网的关系细化,对不同的关系赋予不同的权重。也可以考虑更加新颖的节点影响力算法。

### 参考文献:

- [1] KOREN Y, BELL R, VOLINSKY C. Matrix factorization techniques for recommender systems[J]. Computer, 2009, 42(8): 30-37
- [2] JAMALI M, ESTER M. A matrix factorization technique with trust propagation for recommendation in social networks[C]//Proceedings of the fourth ACM conference on Recommender systems, 2010: 135-142
- [3] ZHANG Fuzheng, JING Nicholas, LIAN Defu. Collaborative knowledge base embedding for recommender systems[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2016: 353-362
- [4] WANG Hongwei, ZHANG Fuzheng. DKN: deep knowledge-aware network for news recommendation[C]//Proceedings of the 2018 World Wide Web Conference, 2018: 1835-1844
- [5] YU Xiao, REN Xiang, SUN Yizhou. Personalized entity recommendation: a heterogeneous information network approach[C]//Proceedings of the 7th ACM International Conference on Web Search and Data Mining, 2014: 283-292
- [6] ZHAO Huan, YAO Quanming, LI Jianda. Metagraph based recommendation fusion over heterogeneous information networks[C]//Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2017: 635-644
- [7] WANG Hongwei, ZHANG Fuzheng, WANG Jialin. Exploring high-order user preference on the knowledge graph for recommender systems[J]. ACM Transactions on Information Systems, 2019, 37(3): 1-26

- [8] FREEMAN L C. Centrality in social networks conceptual clarification[J]. *Social Networks*, 1978, 1(3): 215-239
- [9] FREEMAN L C. A set of measures of centrality based on betweenness[J]. *Sociometry*, 1977, 40(1): 35-41
- [10] SABIDUSSI G. The centrality index of a graph[J]. *Psychometrika*, 1966, 31(4): 581-603
- [11] 丁连红, 孙斌, 时鹏. 知识图谱复杂网络特性的实证研究与分析[J]. *物理学报*, 2019, 68(12): 324-338  
DING Lianhong, SUN Bin, SHI Peng. Empirical study of knowledge network based on complex network theory[J]. *Journal of Physics*, 2019, 68(12): 324-338 (in Chinese)
- [12] 樊燕妮, 刘三阳, 白艺光. 基于多尺度中心性算法的复杂网络节点影响力研究[J]. *数学的实践与认识*, 2020, 50(10): 159-167  
FAN Yanni, LIU Sanyang, BAI Yiguang. Identifying critical nodes in complex networks based on multi-scale centrality algorithm[J]. *The Practice and Understanding of Mathematics*, 2020, 50(10): 159-167 (in Chinese)

## Recommended method study based on incorporating complex network ripple net

LUO Yutai, XU Tao, XU Zhangbo

(Key Laboratory of China's Ethnic Languages and Information Technology of Ministry of Education, Northwest Minzu University, Lanzhou 730030, China)

**Abstract:** The RippleNet network models user preferences and is well applied in the recommended system. But Ripplenet didn't take into account the weight of entities in the knowledge graph, resulting in the inaccurate recommendation results. A RippleNet model incorporating the influence of the complex network nodes is proposed. After constructing the complex networks based on the knowledge maps, the maximum subnet model is extracted, the influence of the nodes in the map network is calculated, and the weight of the nodes is added to the RippleNet model as an entity. The experimental results showed that the present method increased the AUC and ACC values of RippleNet to 92.0% and 84.6%, made up for the problem that no entity influence was considered in the RippleNet network, and made the recommended results more in line with users' expectations.

**Keywords:** knowledge graph; recommended system; complex network; node influence; rippleNet

**引用格式:** 罗宇泰, 徐涛, 徐章博. 基于联合复杂网络 Cn-RippleNet 模型的推荐方法[J]. *西北工业大学学报*, 2021, 39(5): 1070-1076

LUO Yutai, XU Tao, XU Zhangbo. Recommended method study based on incorporating complex network ripple net[J]. *Journal of Northwestern Polytechnical University*, 2021, 39(5): 1070-1076 (in Chinese)