

融入逻辑规则的知识图谱推荐模型研究

高文馨^{1,2}, 李贯峰^{1,2*}, 王云丽¹, 胡德洲¹, 李瑞¹

(1. 宁夏大学 信息工程学院, 宁夏 银川 750021;

2. 宁夏“东数西算”人工智能与信息安全重点实验室, 宁夏 银川 750021)

摘要: 知识图谱嵌入技术已在推荐系统领域引起广泛关注, 将结构化知识图谱中的信息融入到推荐模型中, 可以提高推荐的个性化程度。然而, 因为初始数据的不准确性会导致推荐结果不正确, 现存的知识图谱推荐模型中仍存在误差传播问题。针对这个问题, 该文提出了 RR-KGE 模型, 由知识图谱嵌入模块和推荐算法模块组成; 其中聚焦于知识图谱嵌入框架, 将规则嵌入和知识图谱嵌入进行联合学习, 通过规则给予模型更多的约束条件, 以减少误差传播; 并结合此框架将推荐算法 ALS (Alternating Least Squares) 和 RNN (Recurrent Neural Network) 相融合来获得更加精确的推荐结果; 最后将 RR-KGE 与不同基准模型进行比较, 在两个数据集上多项指标均优于对比模型, 证明了推荐方法的有效性。

关键词: 知识图谱; 知识图谱嵌入; 逻辑规则; 推荐算法; 联合学习

中图分类号: TP391

文献标识码: A

文章编号: 1673-629X(2024)09-0109-07

doi: 10. 20165/j. cnki. ISSN1673-629X. 2024. 0180

Research on Knowledge Graph Recommendation Models Integrated with Logical Rules

GAO Wen-xin^{1,2}, LI Guan-feng^{1,2*}, WANG Yun-li¹, HU De-zhou¹, LI Rui¹

(1. School of Information Engineering, Ningxia University, Yinchuan 750021, China;

2. Ningxia “East Calculation West Algorithm” Artificial Intelligence and Information Security Key Laboratory,
Yinchuan 750021, China)

Abstract: Knowledge graph embedding technology has attracted widespread attention in the field of recommendation systems. Integrating information from structured knowledge graphs into recommendation models can enhance the personalization of recommendations. However, existing knowledge graph recommendation models still face the issue of error propagation due to the inaccuracy of initial data, which leads to incorrect recommendation results. To address this problem, we propose the RR-KGE model, consisting of a knowledge graph embedding module and a recommendation algorithm module. The focus is on the knowledge graph embedding framework, where rule embedding and knowledge graph embedding are jointly learned. Rules provide the model with additional constraints to reduce error propagation. This framework is combined with the recommendation algorithms ALS (Alternating Least Squares) and RNN (Recurrent Neural Network) to obtain more accurate recommendation results. Finally, RR-KGE is compared with different baseline models, and multiple metrics on two datasets demonstrate its superiority over the comparison models, confirming the effectiveness of the recommendation approach.

Key words: knowledge graph; knowledge graph embedding; logical rules; recommendation algorithm; joint learning

0 引言

随着信息时代的发展, 推荐系统成为了各种应用领域的重要组成部分。推荐算法的核心目标是满足用户需求提供个性化推荐。知识图谱^[1] (knowledge graph, KG) 是由实体和关系组成的多关系图, 通常用三元组来表示。知识图谱为推荐系统提供了丰富的语

义关系和实体属性信息, 可以帮助解决传统推荐系统中的数据误差性等问题。

然而, 如果初始数据存在错误, 这可能导致模型学习到不准确的用户兴趣或物品特征, 误导性的初始数据会在误差传播过程中放大, 影响模型对用户行为的理解, 最终导致推荐结果的不准确性。因此, 规则的引

收稿日期: 2024-01-23

修回日期: 2024-05-24

基金项目: 国家自然科学基金项目(62066038); 宁夏自然科学基金项目(2022AAC03026); 宁夏大学研究生创新项目(CXXM202356)

作者简介: 高文馨(1998-), 女, 硕士, CCF 会员(T3641G), 研究方向为基于知识图谱的推荐系统; 通信作者: 李贯峰(1979-), 男, 副教授, 博士, CCF 会员(78326M), 研究方向为语义计算、知识图谱。

人可以弥补推荐系统在处理误差传播问题时,增强系统的性能和可用性。

例如,在推荐系统中,用户行为的多样性和规律性对于提高系统性能至关重要。以三个用户为例,每个用户都展现了独特的电影观影偏好。用户 A 更倾向于选择科幻冒险类电影,用户 B 对以名人演员为特色的电影产生兴趣,而用户 C 则偏好黑白电影或者以古典音乐为主题的影片。从这些行为中,可以发现一些共同的基本规则^[2],即(1)用户主要根据电影类型进行选择(适合 A), (2)用户主要根据演员进行选择(适合 B), (3)用户主要根据影片的色调或音乐风格进行选择(适合 C)。将用户行为动机与个性化特征相结合,通过提取行为规则,可以更准确地找到相似的用户,从而提高推荐系统的准确性。

与以往只关注知识图谱单独应用的研究工作相比,该文将知识图谱嵌入^[3]视为整个推荐过程中的上游任务,从推荐任务的多样性角度出发全面研究了 KGE 与推荐任务中不同算法的创新融合方式。并提出了一种知识图谱嵌入的框架,嵌入模块进行知识图谱嵌入和规则嵌入的联合学习,以提供准确和可解释的建议;然后基于此框架与推荐算法相结合,够更好地处理误差传播问题并给出可解释的推荐。该文的主要贡献如下:

- 提出了一种知识图谱嵌入框架,将知识图谱的三元组嵌入和规则嵌入进行联合学习,以实现更优的性能。
- 基于知识图谱框架利用 RNN 对 ALS 推荐算法进行改进,使 RNN 算法进一步捕捉序列数据中的关系,从而提取出它们之间的关联性和流行度等特征,从而更准确地预测用户兴趣和行为。
- 在真实世界的数据集上进行广泛的实验,实验结果证明了该框架在推荐方面的准确性。

1 相关工作

1.1 基于知识图谱嵌入的推荐模型

基于知识图谱嵌入的推荐算法通过增强项目语义或建模细粒度用户偏好有助于提升推荐准确性,它通过学习实体和关系之间的相似性、分析路径信息和综合多种方法的优势来提供更准确的推荐结果。

TransE^[4]作为最具代表性的平移距离模型,经常被用于推荐系统中的知识图谱嵌入以提升推荐可解释性。Ai 等^[5]提出基于知识图谱的协同过滤架构,采用 TransE 建模多类型用户行为和项目属性并将协同关系编码为关系图结构,在其基础上延伸协同过滤算法学习实体表示以挖掘潜在用户偏好。进一步设计软匹配算法寻找用户到项目的解释路径,结合广度优先搜

索和软匹配公式计算路径概率得到最佳路径以生成推荐的自然语言解释。

Zhang 等^[6]提出 CKE 推荐模型,其是一种基于知识图谱和协同过滤的混合推荐模型。它将用户、物品和知识图谱中的实体(如标签、类别、属性等)映射为低维向量表示,并利用这些向量来计算用户和物品之间的关联度。Wang 等^[7]提出 DKN,一种结合知识图谱和用户点击行为的新闻推荐方法,通过更深入地理解新闻文章的语义信息,提高了推荐系统的性能。Wang 等^[8]提出 MKR,该论文提供了一种结合多任务学习和知识图谱嵌入的方法,以提高推荐系统的性能,尤其是在面对丰富实体关系的情境下。

Wang 等^[9]提出了一种融合 KG 嵌入和路径挖掘的方法(RippleNet)。RippleNet 首先获得与用户点击历史中项目相对应的 KG 多跳实体集,然后沿着 KG 高阶链接扩展实体以捕获用户潜在兴趣偏好,为增强推荐可解释性提供了新观点。基于 RippleNet 偏好传播的理念,Lin 等^[10]提出一种结合项目嵌入和路径推理的方法(CEPA),基于 KG 高阶链接传播实体嵌入,并在传播过程中结合项目嵌入和路径注意力权重捕获细粒度的用户偏好,使用 LSTM 预测用户对项目的潜在兴趣。Liu 等^[11]提出联合因子发现和嵌入学习的可解释推荐模型,梳理出嵌入表示的层次因子并融入到 GCN 中,通过学习用户和项目在不同层次上的特征表示增强推荐可解释性。Cao 等^[12]则基于 GCN 和知识图谱提出一种描述增强的推荐方法(KGNN^[13]),聚合实体的高阶邻域信息并结合文本协同过滤增强实体的文本语义为推荐提供了可靠的解释。

基于知识图谱的推荐系统虽然具有强大的信息结构,但也存在一些缺陷。知识图谱可能难以应对实时和动态的数据更新。相比知识图谱,规则更容易适应动态环境的变化,也使得推荐结果的生成过程更易于理解和解释,提高了系统的可解释性和可控性。因此,有部分研究者将规则引入推荐系统中。

1.2 基于逻辑规则的推荐模型

Chen 等^[14]提出 IR-Rec,该模型通过挖掘知识图谱中的复杂规则来增强推荐算法。规则可能涵盖实体之间的属性和关系等信息,使得推荐系统更具语义理解。Ma 等^[15]提出 RuleRec,目标是通过结合知识图谱的结构信息提高推荐系统的准确性和个性化水平,使其能够更好地适应复杂的推荐场景。Spillo G 等人^[16]提出基于神经符号图嵌入和一阶逻辑规则的知识感知推荐,文章提出了一种融合了神经网络和符号逻辑的方法,以更好地利用知识图谱中的信息来进行个性化推荐。Wu 等人^[17]提出 NLQ4Rec 模型,探讨了如何将神经网络与符号逻辑相结合,以构建一个推荐模型,该

模型能够利用逻辑查询来更好地理解 and 推断用户的偏好,从而提高推荐的准确性和个性化水平。

逻辑规则的引入赋予了模型推理的能力,使其更深入理解用户行为,从而产生更为精准和个性化的推荐结果。

然而,现存的这些模型仍存在一个问题,如果初始数据中存在错误或不准确的信息,尤其是面对在复杂环境中逻辑规则的不确定性,会导致误差传播。对此,该文将逻辑规则一同嵌入,与知识图谱嵌入联合学习,有效地克服不足,进而提高推荐系统的性能。

2 模型

RR-KGE 模型的整体框架如图 1 所示,包括嵌入模块和推荐模块。嵌入模块由规则嵌入和知识图谱嵌入两部分组成;在嵌入模型中,规则嵌入是 RR-KGE 的核心,其内容涵盖规则提取和规则嵌入两个步骤。在模型训练过程中,RR-KGE 对知识图谱嵌入的损失函数和规则嵌入的损失函数进行加权。最终,经过推荐算法的过滤和排序,模型输出最终的推荐结果。

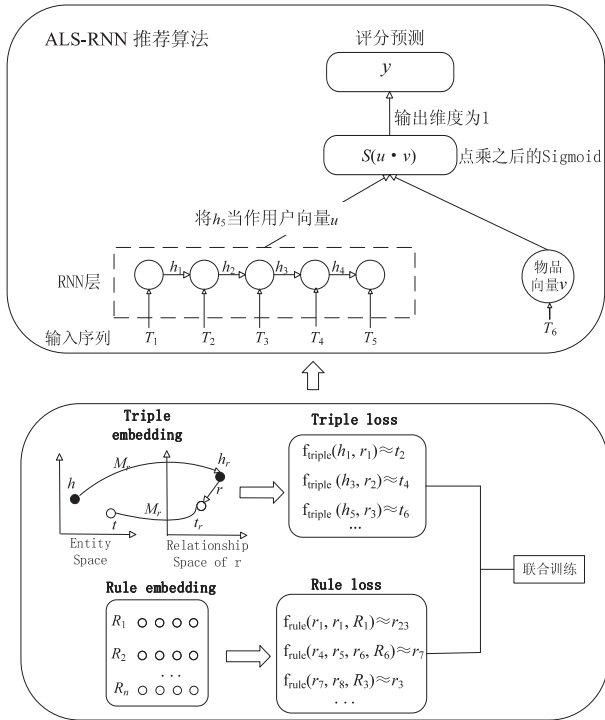


图 1 RR-KGE 模型

2.1 嵌入学习

2.1.1 知识图谱嵌入

异构网络中有着编码实体的结构化信息即其丰富的关系,为了获得这种结构化的信息,当前最有效的方法是将这些信息嵌入到一个连续的向量空间中。该文采用 TransR^[18] 网络嵌入方法,它不同于其他方法假设实体和关系嵌入到同一个空间中,表示了实体和关系在不同的语义空间中,由关系特定矩阵桥接。

知识图谱 $G = (\nu, \varepsilon)$, $\nu = \{\nu_1, \nu_2, \dots, \nu_{|\nu|}\}$ 是指不同实体的一组顶点, ε 是指这些实体之间不同类型关系的一组边。在 TransR 中,对于三元组 (h, r, t) , 实体嵌入设置为 $h, t \in \mathbf{R}^k$, 关系嵌入设置为 $r \in \mathbf{R}^d$, 对每个关系 r , 设置一个映射矩阵 $M_r \in \mathbf{R}^{k \times d}$, 其能将实体从实体空间投影到关系空间。通过映射矩阵,定义实体的投影向量为:

$$\begin{aligned} h_r &= hM_r \\ t_r &= tM_r \end{aligned} \quad (1)$$

对应的得分函数为:

$$f_r(h, t) = \|h_r + r - t_r\|_2^2 \quad (2)$$

损失函数为:

$$L_l = \sum_{(h, r, t) \in S} \sum_{(h', r', t') \in S'} [\gamma + f_r(h, t) - f_r(h', t')]_+ \quad (3)$$

其中, γ 是边界, S 是正确的三元组集合, S' 是不正确的三元组集合。

2.1.2 规则嵌入

对于规则提取方面,选用 AMIE3 挖掘工具,该规则挖掘工具采用了许多复杂的剪枝策略、并行化和优化算法,使得系统可以挖掘大型知识图谱上的规则。

关于知识库 K 中规则 R 的支持度 $\text{supp}(R)$, 它是指在知识库中做出的真实预测 p 的大小,也就是 $R(h, t)$ 的数量。它的计算公式为:

$$\text{supp}(R) = |\{p : (K \wedge R) = p\} \cap p \in K| \quad (4)$$

如果反例由 PCA 选择,那么该置信度称为 PCA 置信度,它的计算公式为:

$$\text{PCA}_{\text{conf}}(B \rightarrow r(h, t)) = \frac{\text{supp}(B \rightarrow r(h, t))}{|\{(h, t) : \exists t' : B \wedge r(h, t')\}|} \quad (5)$$

给定一个三元组 $(h, r, t) \in K$ 和一个规则 $l \in L$, 用 $(h, r, t), r \in \mathbf{R}^{2k}$ 分别表示它们的嵌入。

为遵循逻辑规则的顺序有序性,将存在于规则中的每个关系嵌入 r_i 与规则嵌入 r 进行连接,后将连接后的嵌入传递到 RNN 生成的规则头 r_{l+1} , 其输入预计接近规则头嵌入 r_{l+1} 。该距离函数的表达式为:

$$d(R, r_1, r_2, \dots, r_{l+1}) = \| \text{RNN}([R, r_1], [R, r_2], \dots, [R, r_l]) - r_{l+1} \| \quad (6)$$

逻辑规则为 $R: r_{i_1} \wedge r_{i_2} \wedge \dots \wedge r_{i_n} \rightarrow r_{i_{n+1}}$, 通过使用优化的参数来计算每个规则的置信度分数,计算公式为:

$$w_i = \gamma_r - d(R, r_{i_1}, r_{i_2}, \dots, r_{i_{n+1}}) \quad (7)$$

然后应用 MLP^[19] 来计算规则得分:

$$s_g(h, r, t) = \text{MLP}(\text{LN}(\sum_{R_i \in L} w_i |p(h, r, t) \cap R_i^{(g)})) \quad (8)$$

其中, LN 为层归一化操作, $p(h, r, t)$ 为规则 R_i 的支持集。最后,通过最大化训练三元组中真答案的对数

似然来训练 MLP 和基础阶段规则嵌入。

将在规则主体或头部的关系替换成一个随机关系,对规则损失函数的定义为:

$$L(R, r_1, r_2, \dots, r_{l+1}) = -\log\sigma(d(R, r_1, r_2, \dots, r_{l+1})) - \sum_{(R, r_1, r_2, \dots, r_{l+1}) \in M} \frac{1}{|M|} \log\sigma(d(R, r_1, r_2, \dots, r_{l+1}) - \gamma_r) \quad (9)$$

其中, γ_r 表示固定的规则裕度, M 是负规则采集样本。

KG 若包含一个三元组 K 和逻辑规则 L , 则联合优化实体、关系和规则嵌入, 损失函数为:

$$L_g = \sum_{(h, r, t) \in K} L(h, r, t) + \alpha \sum_{(R, r_1, r_2, \dots, r_l) \in L} L(R, r_1, r_2, \dots, r_l) \quad (10)$$

其中, α 是一个正超参数。

经过前两部分的结构向量化和规则向量化, 结合 KGE 损失函数 L_t 和规则损失函数 L_g , 加权后的总损失函数为 L_{weighted} , 可以表示为:

$$L_{\text{weighted}} = \beta \cdot L_t + (1 - \beta) \cdot L_g \quad (11)$$

其中, β 是权重参数, 用于控制知识图谱嵌入和规则嵌入在总损失函数中的贡献比例。因该文更侧重于规则嵌入时的学习任务, 通过实验已得出 $L_t = 0.1$, $L_g = 0.3$, 选择较小的 β , 即 $\beta = 0.2$ 。

在训练过程中, 通过优化这个加权的总损失函数, 以更好地学习模型参数。

2.2 ALS+RNN

由于 RNN 强调了用户的即时行为, 即根据用户之前时刻的动作来预测下一时刻该用户的动作, 因此提出将矩阵分解协调过滤算法 ALS 结合 RNN 来改善推荐模型的预测能力问题。

ALS 的中心思想是求用户向量和物品向量的点积。设某用户特征向量与某物品特征向量的总数量为 n , 每个特征维度为 k , 将其拼接后成一个形状为 $n \times k$ 的二维矩阵, 对该矩阵进行卷积操作从而达到特征向量聚合的效果, 后经过几层全连接层得到模型的输出。

在 RNN 的计算环境中, 通过 RNN 提取上下文信息, 可以将用户历史交互的物品序列当作用户本身, 聚合物品序列的向量, 与目标物品的向量表示进行点积运算, 有效减少误差传播。

每个 RNN 节点的公式为:

$$h_t = \tanh(w_{ih}x_t + b_{ih} + w_{hh}h_{t-1} + b_{hh}) \quad (12)$$

$w_{ih}x_t + b_{ih}$ 是一个线性回归方程, x_t 是 t 时刻的输入。

单纯的一个 RNN 节点输出的只是一个隐藏向量 h , 如果要完成一个字的预测还需要接一个全连接层, 并将输入的向量再进行 Softmax 激活一下, 如何与真实的类别建立交叉熵损失函数, 方便进行多类预测, 公

式如下:

$$\begin{cases} \hat{y}_t = \text{softmax}(w_{hn}h_t + w_{nn}) \\ \text{loss} = \sum_0^t \text{crossEntropyLoss}(\hat{y}_t, y_t) \end{cases} \quad (13)$$

将 ALS 和 RNN 进行结合, 结构上将目标物品单独提出后作为 ALS 上所谓的物品向量, 而由物品组成的序列经过 RNN 层消息传递后, 取 RNN 最后一个节点的输出向量作为下一个全连接层的输入, 得到的最后一层输出当作用户向量, 对用户和物品向量分别进行几个隐藏层的映射之后进行点乘计算。RNN 网络训练过程中, 对于矩阵填充的方式依旧采用 ALS 计算方式, 即固定其中一个矩阵来更新另一个矩阵, 不同之处在于填充矩阵的顺序考虑了时间因素。最终 RNN 网络计算出下一时刻用户可能想要的概率值并给出预测的评估, 最终产生推荐。

3 实验设计与分析

在本节中, 将在两个应用场景中评估提出的 RR-KGE 模型。首先介绍了数据集、基线和实验设置, 然后给出了实验结果。

3.1 实验设计

3.1.1 数据集

在实验中使用了以下数据集, 如表 1 所示。

表 1 数据集

	MovieLens-1M	Amazon-book
#users	5 883	70 679
#items	3 230	24 915
#interaction	226 101	847 733

MovieLens-1M: MovieLens-1M 由 6 040 个用户和 3 706 部电影的 1M 个评分组成。为了与隐式反馈设置保持一致, 只提取正面评分用于训练和测试。在删除正面评价少于 3 个的用户后, 在最终数据集中有 5 883 个用户, 3 230 部电影和 226 101 个评分。此外, 只有 134 部电影不能从知识库中映射到任何电影实体。接下来, 为了构建结构化知识, 从中提取一个子图, 其中包含项目实体以及相应的关系。电影实体包括类型、导演、作家、演员、语言、国家、制作日期、评分、提名奖项和获奖情况。

Amazon-book: Amazon-review 是一个广泛使用的产品推荐数据集。从中选择 Amazon-book。为了确保数据集的质量, 使用 10 核设置, 即保留至少 10 个交互的用户和项目。

3.1.2 基准

将提出的 RR-KGE 与以下基线进行比较:

- CKE^[6]: 将 CF 与结构知识、文本知识和视觉知

识结合在一个统一的推荐框架中。

- **DKN^[7]**:将实体嵌入和词嵌入作为多个通道,在 CNN 中将它们组合在一起进行 CTR 预测。

- **MKR^[8]**:是一个通用的、端对端的深度推荐框架,整个框架可以通过交替优化两个任务来被训练,使 MKR 有高度的灵活性和适应性。

- **RippleNet^[9]**:将知识图谱整合到推荐系统中的先进算法。它刺激用户偏好在知识实体集上的传播,从而了解用户的潜在兴趣。

- **IR-Rec^[14]**:将公共行为规则与用户的个性特征相结合,提出符合用户个性化兴趣的推荐。

- **RuleRec^[15]**:研究使用大规模知识图谱 Freebase 进行规则学习,灵活地增强不同的推荐算法。

3.1.3 评价指标

该文采用了 3 个广泛使用的评价指标来评估方法,包括 Precision, Accuracy 和 Recall。

$$Accuracy = \frac{TP + TN}{P + N} \quad (14)$$

$$Precision = \frac{TP}{TP + FP} \quad (15)$$

$$Recall = \frac{TP}{P} + \frac{TP}{TP + FN} \quad (16)$$

其中, Precision 和 Recall 得分越高,性能越好。Accuracy 是评价分类的综合指标。

3.2 实验结果与评估

3.2.1 与基于知识图谱嵌入的推荐模型比较

本部分的实验旨在比较基于知识图谱嵌入的推荐模型在推荐性能上的表现,以及与其他推荐算法的差异。在实验中,每个数据集按 8 : 1 : 1 的比例随机分为一个训练集和一个测试集,将用户-物品对设置为正反馈,如果它们之间存在评级或交互,则目标值为 1,否则为 0。

对于训练集中的每个正对,采用负采样策略匹配负项。在测试过程中,将阳性和阴性样本的比例设置为 1 : 100。在 RR-KGE 中选择 Adam 作为迭代器,其学习率设置为 0.005,批大小设置为 1 024。所有实验重复 5 次,5 轮的平均值作为最终结果。最终结果展示如表 2 所示。

表 2 与基于知识图谱嵌入的推荐模型比较结果

Dataset	Method	CKE	MKR	DKN	RippleNet	RR-KGE
MovieLens-1M	Accuracy	0.845	0.885	0.845	0.832	0.891
	Precision	0.797	0.864	0.828	0.836	0.907
	Recall	0.866	0.867	0.811	0.833	0.911
Amazon-book	Accuracy	0.821	0.875	0.795	0.852	0.886
	Precision	0.849	0.892	0.793	0.831	0.894
	Recall	0.841	0.881	0.774	0.849	0.899

3.2.2 与基于逻辑规则的知识图谱推荐模型比较

本部分的实验旨在比较基于逻辑规则的知识图谱推荐模型与其他推荐算法的性能,探讨逻辑规则在推荐系统中的适用性。将项目与每个用户之间的最新交互作为测试集中的正项目,剩余的数据用于训练。由于研究中的损失函数是成对的,所以训练集中的每个正项都会用一个负项来训练从用户未交互的项中采样的项。对于测试集,由于在评价中对每个用户的所有项目进行排序过于耗时,因此随机抽取 99 个与用户没有交互的负面项目加入测试集。因此,在测试集中,每个用户被评估为 99 个负面项目和 1 个正面项目。最终结果展示如表 3 所示。

首先可以看到,方法在所有指标上都达到了最好的性能,并且改进是显著的,这表明规则权重学习有很大的帮助,可以获得更好的推荐结果。

在实验中,使用了 Accuracy, Precision, Recall 来衡量模型的性能。将实验组与对照组进行了比较,对比组别包括:基于知识图谱嵌入的推荐模型、基于逻辑规

则的知识图谱推荐模型。从对比中发现的模型整体上相较于对照组表现更好,因为规则对于用户行为的表现进行了约束,减少了误差传播,这有助于理解模型在不同条件下的适用性。

表 3 与基于逻辑规则的知识图谱推荐模型比较

Dataset	Method	IR-Rec	RuleRec	RR-KGE
MovieLens-1M	Accuracy	0.793 4	0.796 4	0.811 4
	precision	0.737 6	0.772 6	0.786 2
	recall	0.688 2	0.811 4	0.813 8
Amazon-book	Accuracy	0.784 4	0.755 3	0.795 6
	precision	0.769 5	0.781 7	0.783 4
	recall	0.682 7	0.736 5	0.799 7

任务 1 的比较:如图 2,在 MovieLens-1M 和 Amazon-book 两个数据集上,观察到 Precision 指标在不同批次下的变化趋势。对于 CKE、MKR、DKN 和 RippleNet 四个模型,随着批次的增加, Precision 指标的值在两个数据集上有小幅提升。在 MovieLens-1M

上,CKE 从 0.761 上升至 0.772, MKR 从 0.762 上升至 0.77, DKN 从 0.764 上升至 0.771, RippleNet 从 0.764 上升至 0.772。在 Amazon-book 上,CKE 从 0.752 上升至 0.763, MKR 从 0.748 上升至 0.753, DKN 从 0.753 上升至 0.76, RippleNet 从 0.755 上升至 0.76。这表明这些模型在更大批次下能够更准确地预测用户是否喜欢某项物品。另外,RR-KGE 模型在两个数据集上也表现出了相似的趋势。在 MovieLens-1M 上,RR-KGE 的 Precision 从 0.765 上升至 0.773;而在表明该模型在更大批次下能够更精确地预测用户喜好。




图 2 Precision 指标在不同批次下的变化趋势

总体来说,随着批次从 20% 增加到 60%,两个数据集上的模型在 Precision 指标上都有一定的提升。这表明增加批次可以帮助模型更好地学习数据分布,从而提高推荐的准确性。这一发现对于实际应用中如何选择合适的批次以平衡计算资源和推荐精度具有一定的指导意义。

任务 2 的比较:如图 3,在 MovieLens-1M 和 Amazon-book 两个数据集上,观察到 Recall 指标在不同批次下的变化趋势。对于 IR-REC,随着批次的增加,其在两个数据集上的值均呈现上升趋势。在 MovieLens-1M 上,从 0.783 上升至 0.786;在 Amazon-book 上,从 0.774 上升至 0.779。这表明模型在更大批次下能够更全面地挖掘出潜在的相关记录。在 MovieLens-1M 上,RuleRec 从 0.779 上升至 0.787;而在 Amazon-book 上,其值从 0.774 微升至 0.779。这表明模型在更多数据下能更好地应用规则进行推荐。

在 MovieLens-1M 上,RR-KGE 从 0.781 上升至 0.788;而在 Amazon-book 上,其值从 0.778 上升至 0.782。这表明模型在更大批次下能够更准确地找到与查询相关的项。




图 3 Recall 指标在不同批次下的变化趋势

综上,随着批次从 20% 增加到 60%,两个数据集上的模型性能在 Recall 指标上都有显著提升。这支持了假设,即在更大的数据集上训练模型可以提高推荐性能。

4 结束语

该文致力于推进推荐系统中知识图谱嵌入技术的应用,以更好地实现推荐的个性化。在面对初始数据不准确引发的误差传播问题时,提出了 RR-KGE 模型。此模型通过联合学习规则嵌入和知识图谱嵌入有效地解决了误差传播。此外,为了进一步提升推荐准确性,采用了 ALS 和 RNN 这两种推荐算法,融合在 RR-KGE 框架中,以形成更为综合和高效的推荐模型。在验证阶段,将 RR-KGE 与多个基准模型进行了对比分析,结果表明在两个不同的数据集上,RR-KGE 展现出良好的性能水平,突显了该框架在提高推荐系统性能方面的显著效果。

未来,计划研究如何设计一种基于嵌入学习的组合算法,使推荐结果可以用知识图谱解释。这些未来研究方向将进一步推动知识图谱嵌入技术在推荐系统中的创新和应用,为用户提供更个性化、时序性强的推荐服务。

参考文献:

- [1] PAULHEIM H. Knowledge graph refinement: a survey of approaches and evaluation methods[J]. *Semantic Web*, 2017, 8(3): 489–508.
- [2] 封皓君, 段立, 张碧莹. 面向知识图谱的知识推理综述[J]. *计算机系统应用*, 2021, 30(10): 21–30.
- [3] 张天成, 田雪, 孙相会, 等. 知识图谱嵌入技术研究综述[J]. *软件学报*, 2023, 34(1): 277–311.
- [4] BORDES A, USUNIER N, GARCIA-DURAN A, et al. Translating embeddings for modeling multi-relational data[J]. *Advances in Neural Information Processing Systems*, 2013, 26(7): 26–32.
- [5] AI Q, AZIZI V, CHEN X, et al. Learning heterogeneous knowledge base embeddings for explainable recommendation[J]. *Algorithms*, 2018, 11(9): 137.
- [6] ZHANG F, YUAN N J, LIAN D, et al. Collaborative knowledge base embedding for recommender systems[C]//Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining. San Francisco: ACM, 2016: 353–362.
- [7] WANG H, ZHANG F, XIE X, et al. DKN: deep knowledge aware network for news recommendation[C]//Proceedings of WWW '18: the web conference 2018. Lyon: WWW, 2018: 1835–1844.
- [8] WANG H, ZHANG F, ZHAO M, et al. Multi-task feature learning for knowledge graph enhanced recommendation[C]//Proceedings of WWW '19: the web conference. San Francisco: WWW, 2019: 2000–2010.
- [9] WANG H, ZHANG F, WANG J, et al. Ripplenet: propagating user preferences on the knowledge graph for recommender systems[C]//Proceedings of the 27th ACM international conference on information and knowledge management. Torino: ACM, 2018: 417–426.
- [10] LIN Y, XU B, FENG J, et al. Knowledge-enhanced recommendation using item embedding and path attention[J]. *Knowledge-Based Systems*, 2021, 233: 107484.
- [11] LIU N, GE Y, LI L, et al. Explainable recommender systems via resolving learning representations[C]//Proceedings of the 29th ACM international conference on information & knowledge management. Ireland: ACM, 2020: 895–904.
- [12] CAO X, SHI Y, YU H, et al. DEKR: description enhanced knowledge graph for machine learning method recommendation[C]//Proceedings of the 44th international ACM SIGIR conference on research and development in information retrieval. Canada: ACM, 2021: 203–212.
- [13] LIN X, QUAN Z, WANG Z J, et al. KGNN: knowledge graph neural network for drug interaction prediction[C]//Proceedings of international joint conference on artificial intelligence. Kyoto: [s. n.], 2020: 2739–2745.
- [14] CHEN J, YU J, LU W, et al. IR-Rec: an interpretive rules-guided recommendation over knowledge graph[J]. *Information Sciences*, 2021, 563: 326–341.
- [15] MA W Z, ZHANG M, CAO Y, et al. Jointly learning explainable rules for recommendation with knowledge graph[C]//Proceedings of the 2019 world wide web conference. San Francisco: ACM, 2019: 1210–1221.
- [16] SPILLO G, MUSTO C, DE GEMMIS M, et al. Knowledge-aware recommendations based on neuro-symbolic graph embeddings and first-order logical rules[C]//Proceedings of the 16th ACM conference on recommender systems. Seattle: ACM, 2022: 616–621.
- [17] WU M, CHEN B, ZHU S, et al. Neuro symbolic recommendation model based on logic query[J]. *Knowledge-Based Systems*, 2023, 24(2): 1113–1116.
- [18] HUANG W, LI G, JIN Z. Improved knowledge base completion by the path-augmented TransR model[C]//Knowledge science, engineering and management; 10th international conference. Melbourne: Springer, 2017: 149–159.
- [19] TOLSTIKHIN I O, HOULSBY N, KOLESNIKOV A, et al. Mlp-mixer: an all-mlp architecture for vision[J]. *Advances in Neural Information Processing Systems*, 2021, 34: 24261–24272.