

基于知识图谱的图神经网络个性化推荐方法研究

文思源

北京邮电大学，北京，100000；

摘要：本文提出了一种基于知识图谱和图神经网络的个性化推荐方法，旨在克服传统推荐方法的局限性。尽管协同过滤和基于内容的推荐方法在实践中有效，但它们难以捕捉深层次的语义关系和用户决策背后的动机。为此，本文引入分区知识图谱嵌入方法，平衡表达能力与计算效率，并将知识图谱增强的嵌入引入图神经网络中。该方法能够更好地捕捉用户偏好，提高推荐的可解释性与准确性。实验结果表明，所提方法在推荐精度方面优于现有方法，验证了其在个性化推荐中的有效性。

关键词：知识图谱；图神经网络；推荐

DOI：10.69979/3041-0673.24.10.034

引言

推荐系统已成为现代应用中的核心，通过个性化推荐帮助用户在大量信息中进行导航，广泛应用于电子商务、内容流媒体和社交媒体等领域。传统推荐方法，如协同过滤和基于内容的推荐，分别在捕捉用户交互模式和物品属性上有其优势。然而，协同过滤忽略了物品内在特征，导致推荐缺乏个性化；而基于内容的方法容易受到过度专业化的影响，限制了推荐的多样性。为克服这些问题，混合推荐方法结合了两者的优点，提供了更准确且多样的推荐^[1]。

近年来，基于知识图谱的推荐方法受到关注，知识图谱通过结构化语义信息提供了更深层次的物品和用户关系理解。结合图神经网络的知识感知推荐方法，通过多跳邻居聚合建模复杂交互，展现出较大潜力。然而，现有方法往往忽视了用户选择背后的动机和个性化差异^{[2][3]}。

本文提出一种新的知识感知推荐方法，结合分区知识图谱嵌入和图神经网络，旨在更准确地建模用户决策过程。主要贡献包括：1) 提出分区知识图谱嵌入方法，平衡表达能力与计算效率；2) 基于用户偏好和物品特征建模用户决策，提升推荐的可解释性与准确性。实验结果表明，所提方法在推荐精度和可解释性上优于现有方法，证明了其在个性化推荐中的有效性。

1 方法

1.1 知识图谱嵌入

传统知识图谱嵌入方法通常将整个嵌入向量视为

一个整体并建模其交互，但这可能导致模型复杂、计算成本高或需要专门的交互机制^[4]。为解决这一问题，我们提出了一种基于分区的嵌入方法，降低计算复杂度并提升表达能力。每个分区专注于不同的语义或结构信息，通过注意力机制，模型可根据任务需求动态调整分区权重，赋予不同分区不同重要性。例如，某些分区聚焦于捕捉实体间关系，其他分区则侧重于语义信息，如实体属性或含义。此方法提高了模型的灵活性、适应性及对复杂知识图谱的理解和推理能力，进而提升推荐准确性。该分区知识图谱嵌入方法包括三个阶段：分区、计算局部交互得分和计算全局交互得分，具体流程如图1所示。




图 1 模型示意图

对知识图谱中每一个三元组 (h, r, t) ，设实体和关

系的嵌入向量为 $\mathbf{h}, \mathbf{t} \in \mathbb{R}^{D_e}$ 和 $\mathbf{r} \in \mathbb{R}^{D_r}$ ，其中 D_e 和 D_r 分别表示实体和关系的嵌入维度。这些嵌入向量被分割成为 K 个分区，每个子向量的维度为 $\mathbf{P}_h = \frac{D_e}{K}$ ， $\mathbf{P}_t = \frac{D_e}{K}$ ， $\mathbf{P}_r = \frac{D_r}{K}$ 。因此，头实体、尾实体和关系的分区嵌入矩阵分别为：

$$E_h^{(k)} \in p_h, E_t^{(k)} \in p_t, E_r^{(k)} \in p_r$$

对于每个分区，我们采用 Tucker 格式进行嵌入向量的交互。设我们需要学习的参数矩阵为 $W \in \mathfrak{R}^{K \times P_h \times P_t \times P_r}$ ，对于第 k 个分区的局部交互得分计算如式 1 所示：

$$\text{Score}^{(k)} = W^{(k)} \times_1 E_h^{(k)} \times_2 E_t^{(k)} \times_3 E_r^{(k)} \quad \text{式 1}$$

其中， $W^{(k)} \in \mathfrak{R}^{P_h \times P_t \times P_r}$ 为第 k 个分区的核心张量， $E_h^{(k)}, E_t^{(k)}, E_r^{(k)}$ 分别为头实体、尾实体和关系在第 k 个分区的嵌入向量表示， $\times_n$ 表示 n -mode 张量乘积。

在得到每个分区的局部交互得分后，为每个分区分配一个权重系数，以权衡该分区对嵌入的整体表示的贡献程度，其具体计算如式 2 所示：

$$\partial_i = \frac{\exp(\text{Score}^{(i)})}{\sum_{j=1}^K \exp(\text{Score}^{(j)})} \quad \text{式 2}$$

其中， ∂_i 表示第 i 个分区的权重系数， $\text{Score}^{(i)}$ 表示第 i 个分区的局部交互得分。得到每个分区的权重系数后，我们会计算最终的交互得分，计算如式 3 所示：

$$\text{Score} = \sum_{i=1}^K \partial_i \text{Score}^{(i)} \quad \text{式 3}$$

1.2 用户决策建模

个性化推荐系统中，用户决策过程是核心研究对象。面对大量信息，用户根据需求、兴趣和偏好做出决策，如何精准建模这一过程成为提升推荐效果的关键。决策树作为经典机器学习方法，以清晰结构和可解释性广泛应用于决策分析。它通过树状结构层次化建模决策过程，每个节点代表决策问题，分支代表选择，叶节点代表最终结果。

我们将决策树思想引入用户决策建模，能够有效模拟用户在不同情境下的选择行为。每层可对应用户决策中的特征，形成从条件到结果的推理路径。与传统线性模型不同，决策树能处理复杂非线性关系，适应用户多样化决策模式。因此，决策树建模能更好地捕捉用户在多变环境中的个性化需求。图 2 示例中，假设某用户喜欢《复仇者联盟》和《钢铁侠》，而不喜欢迈克尔·贝执导的电影。在这种情况下，我们应重点考虑导演对推荐的正面影响，尤其在用户不喜欢的电影导演较少时。

同时，如果某特征（如导演）在正负面项目中均出现，该特征可能对决策影响不大；若迈克尔·贝的电影多出现在负面项目中，则这一特征应作为区分负面项目的标识。我们将利用这些信息调整推荐策略，更精准地理解用户的偏好。




图 2 用户决策示意图

我们通过分区知识图谱嵌入方法，获得实体和关系的嵌入 E_h, E_t, E_r ，这些特征向量用于表征每个实体和关系的语义信息。对于每一个物品 i ，我们定义其语义特征集合 F_i 为知识图谱中关系和尾实体的嵌入组合。例如，对于电影《阿凡达》，其语义特征集为 $\{\langle \text{类型}, \text{科幻片} \rangle, \langle \text{导演}, \text{詹姆斯·卡梅隆} \rangle\}$ ，对于集合中每个语义特征计算方式如式 4 所示：

$$E_f = E_r \parallel E_t, f \in F_i \quad \text{式 4}$$

通过对用户喜欢的物品和决策进行分析，我们利用一组特征 F_{ui} 来描述系统中每个用户和物品交互的决策路径 Path_{ui} ，其表示用户 u 选择物品 i 的原因，计算如式 5 所示：

$$\text{Path}_{ui} = \{(s_{ui}^f, E_f) \mid f \in F_{ui}\} \quad \text{式 5}$$

其中， $s_{ui}^f \in \{-1, 1\}$ 表示语义特征 f 是否在物品内容中存在：如果 $f \in F_i$ ，则 $s_{ui}^f = 1$ ；如果 $f \notin F_i$ ，则 $s_{ui}^f = -1$ 。我们认为，这条路径捕获了特定用户和物品交互的背后逻辑，整体表示了决策路径中语义特征存在和不存在的组合。于是，我们将基于知识感知的决策嵌入建模为式 6：

$$P_{ui} = \frac{1}{|\text{Path}_{ui}|} \sum_{(s_{ui}^f, E_f) \in \text{Path}_{ui}} s_{ui}^f E_f \quad \text{式 6}$$

在完成了基于知识图谱的物品和用户决策过程建模后，接下来我们将对用户和物品进行表示。物品 i 基于内容的嵌入表示如式 7 所示：

$$E_i^K = \frac{1}{|F_i|} \sum_{f \in F_i} E_f \quad \text{式 7}$$

类似于物品的基于内容的表示，用户也可以通过他们在个人历史中采用对的知识感知决策来进行描述。将每个用户表示为其在交互时用于决定是否与某个物品交互的特征组合，设与用户 u 交互过的物品集合为 N_u ，其具体如式 8 所示：

$$E_u^K = \frac{1}{|N_u|} \sum_{i \in N_u} P_{ui} \quad \text{式 8}$$

1.3 基于图神经网络推荐

图神经网络通过迭代更新节点表示，利用邻接节点信息更新特征。在每次迭代中，节点从邻居收集信息，并将其与当前特征结合，生成新的节点表示，直到收敛。传统推荐算法通常通过评分或点击行为表示用户与物品的交互。随着图神经网络的发展，越来越多的推荐算法结合知识图谱，通过知识图谱嵌入将物品语义特征和用户兴趣映射到高维空间，提升推荐准确性。

在基于图神经网络的推荐中，我们结合了从知识图谱中获得的基于内容的物品 E_i^K 和用户嵌入表示 E_u^K 。在模型中，受图卷积神经网络的启发，我们定义了用户和物品基于协同的嵌入表示。对于用户物品交互图中的每个节点 i ，其第 l 层节点的嵌入表示计算如式 9：

$$E_i^{(l)} = \sigma(W^{(l)}(E_i^{(l-1)} + E_{N_i}^{(l-1)})) \quad \text{式 9}$$

其中， $W^{(l)}$ 为第 l 层可学习的参数矩阵， σ 为激活函数， E_{N_i} 为邻居节点嵌入表示的线性组合，即 $E_{N_i} = \sum_{j \in N_i} E_j$ 。经过 l 层图卷积神经网络，我们得

到基于协同的用户和物品的嵌入表示 E_i, E_u 。我们将基于内容的嵌入表示和基于协同的嵌入表示进行连接，并使用内积作为评分函数，最终用户 u 对物品 i 的交互得分计算如式 10：

$$y(u, i) = (E_u^K \parallel E_u)^T (E_i^K \parallel E_i) \quad \text{式 10}$$

1.4 模型优化

在知识图谱嵌入方法的训练阶段，我们的目标是学习嵌入向量和模型参数，以预测每个三元组（头实体、尾实体和关系）在知识图谱中的存在性。训练被建模为二分类问题，预测三元组存在的概率。首先，构建知识图谱中所有实际存在的三元组集合作为真实数据集 D 。由于知识图谱庞大，包含大量实体和关系，真实三元组数以百万计。为提高模型泛化能力并考虑计算资源限制，我们生成负样本集 D' 。使用交叉熵损失函数衡量模型预测概率分布与真实分布的差异，具体如式 11：

$$Loss_{KG} = - \sum_{(h,t,r) \in D \cup D'} (\hat{p} \log p + (1 - \hat{p}) \log(1 - p)) \quad \text{式 11}$$

其中， p 是全局交互得分经过标准的逻辑函数转换得到的概率值，即 $p = \sigma(\text{Score})$ 。

在基于图神经网络的推荐任务中，我们使用 BPR 损失函数来优化模型，如式 12：

$$Loss_{CF} = -\log \sigma(y(u, i^+) - y(u, i^-)) \quad \text{式 12}$$

2 实验结果

在三个推荐数据集上评估了该方法和其他基线算法，从实验结果来看，在三个数据集上相较于其他基线模型均表现出了更优的推荐性能。

表 1 实验结果表

	Facebook Books			MovieLens 1M			Yahoo! Movies		
	NDCG	HR	Recall	NDCG	HR	Recall	NDCG	HR	Recall
CF	0.091	0.275	0.148	0.310	0.874	0.158	0.226	0.507	0.279
LightGCN	0.094	0.294	0.137	0.296	0.881	0.153	0.213	0.498	0.270
Our model	0.102	0.311	0.153	0.318	0.893	0.169	0.231	0.524	0.284

3 总结

本文提出了一种结合知识图谱和图神经网络的个性化推荐方法，旨在解决传统推荐系统中无法充分捕捉用户决策动机和深层语义关系的局限性。通过引入分区

知识图谱嵌入和增强的用户决策建模，本文方法能够更有效地利用知识图谱中的结构化语义信息，捕获用户与物品之间的复杂交互关系。实验结果表明，所提出的方法在推荐精度方面优于现有一些算法，展示了在个性化

推荐中的优势。

参考文献

[1]Ko H, Lee S, Park Y, et al. A survey of recommendation systems: recommendation models, techniques, and application fields[J]. Electronics, 2022, 11(1): 141.
[2]GUO Q, ZHUANG F, QIN C, et al. A Survey on Knowledge Graph-Based Recommender Systems[J/OL]. IEEE Transactions on Knowledge and Data En-

gineering, 2022: 3549-3568.

[3]吴静,谢辉,姜火文. 图神经网络推荐系统综述[J]. Journal of Frontiers of Computer Science & Technology, 2022, 16(10).

[4]孟小艳,蒋同海,周喜,等. 一种改进的自适应知识图谱嵌入式表示方法[J]. Application Research of Computers/Jisuanji Yingyong Yanjiu, 2021, 38(1).

作者简介: 文思源 (2000.07-), 男, 汉族, 湖南株洲人, 研究生 (学历), 研究方向: 推荐算法.