计算机科学 COMPUTER SCIENCE
http://www.jsjkx.com
DOI:10.11896/jsjkx.201000085

基于知识图谱和标签感知的推荐算法

宁泽飞[1]　孙静宇[2]　王欣娟[3]
1 太原理工大学大数据学院　太原 030024
2 太原理工大学软件学院　太原 030024
3 太原理工大学信息与计算机学院　太原 030024
(ningzefei@163.com)

摘　要　推荐系统缓解了互联网数据量剧增带来的信息过载问题,但传统的推荐系统由于数据稀疏和冷启动等问题导致推荐算法的准确性不高。因此,文中提出了一种基于知识图谱和标签感知的推荐算法(Knowledge Graph and Tag-Aware,KGTA)。首先,利用项目和用户标签信息,通过知识图谱表示学习捕获低阶与高阶特征,将两个知识图谱中实体和关系的语义信息嵌入低维的向量空间中,从而获得项目和用户的统一表示。其次,分别利用深度神经网络和加入注意力机制的递归神经网络来提取项目和用户的潜在特征。最后,根据潜在特征预测评分。该算法不仅利用了知识图谱和标签的关系信息和语义信息,而且通过深层结构学习了项目和用户的隐含特征。在 MovieLens 数据集上的实验结果表明,该算法能够有效预测用户评分,提高推荐结果的准确性。

关键词:知识图谱;标签感知;深度学习;注意力机制;推荐算法
中图法分类号　TP391

Recommendation Algorithm Based on Knowledge Graph and Tag-aware

NING Ze-fei[1],SUN Jing-yu[2] and WANG Xin-juan[3]
1 College of Data Science,Taiyuan University of Technology,Taiyuan 030024,China
2 College of Software,Taiyuan University of Technology,Taiyuan 030024,China
3 College of Information and Computer,Taiyuan University of Technology,Taiyuan 030024,China

Abstract　Recommendation systems alleviate the problem of information overload caused by the rapid increase of data on the Internet. But traditional recommendation systems are not accurate enough due to data sparsity and cold start. Therefore,a novel recommendation algorithm based on knowledge graph and tag-aware (KGTA) is proposed. First,tags of items and users are used to capture low-order and high-order features through knowledge graph representation learning. The semantic information of entities and relationships in two knowledge graphs is embedded into a low-dimension vector space to obtain the unified representation of items and users. Then,deep neural networks and recurrent neural networks combining attention mechanism are respectively utilized to extract the latent features of items and users. Finally,ratings are predicted on the basis of latent features. KGTA not only takes relationship information and semantic information of knowledge graph and tags into consideration,but also learns latent features of items and users through deep structures. Experimental results on MovieLens datasets illustrate that the proposed algorithm performs better in rating prediction and improves the accuracy of recommendation.

Keywords　Knowledge graph,Tag-aware,Deep learning,Attention mechanism,Recommendation algorithm

1　引言

随着互联网技术的迅速发展,人类社会进入了信息爆炸的时代。国际数据公司(International Data Corporation,IDC)预测,2025 年全球数据总量将增至 175 ZB[1]。信息的迅速膨胀使得用户可以通过各种途径获取大量信息,与此同时也导致了信息过载问题。推荐系统[2]作为一种能有效缓解该问题的方法,通过分析用户历史行为数据来确定用户偏好并推荐个性化的内容,在网络服务中发挥着重要作用。

传统的推荐算法主要包括基于内容的推荐、协同过滤推荐和混合推荐[3]。基于内容的推荐根据用户已经选择或者评分的项目,挖掘其他内容相似的项目作为推荐。协同过滤是

到稿日期:2020-10-16　返修日期:2021-02-02　本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。
基金项目:山西省“1331 工程”项目(SC19100026);山西省科技厅重点研发计划项目(201803D31226);山西省研究生教改项目(2019JG41)
This work was supported by the “1331 Project” of Shanxi Province(SC19100026),Key Research and Development Plan Project of the Shanxi Province Science and Technology Department(201803D31226) and Graduate Educational Reform Project of Shanxi Province(2019JG41).
通信作者:孙静宇(whitesunpersun@163.com)

推荐算法中的成功典例，通常分为两大类：基于内存的协同过滤和基于模型的协同过滤。算法通过计算用户或项目之间的相似度来挖掘相似的用户或项目，并向用户推荐其感兴趣的项目。混合推荐算法的主要思想是将上述推荐方法相结合，以便充分利用用户和项目的信息。然而，由于系统结构的日益复杂和用户数量的不断增加，传统的推荐算法遇到了一系列挑战，包括冷启动、数据稀疏和用户兴趣漂移等[4]。

随着互联网中越来越多的数据可以被感知获取，包括标签、图像、文本在内的多源异构辅助信息，可以用来丰富对用户的个性化需求和项目的描述，增强推荐算法的挖掘能力，从而有效地缓解数据稀疏和冷启动等问题，提高推荐算法的准确性、多样性和可解释性。因此，融合多源异构辅助信息的混合推荐算法在近年来得到了越来越广泛的研究与应用[5]。

标签是一种无层次化结构、用于描述信息的关键词，可以用来描述项目的语义[6]。许多基于网络的信息服务系统，如视频推荐系统 YouTube、文献推荐系统 CiteULike、商品推荐系统 Amazon、微博、豆瓣等，允许用户为项目添加标签，以方便用户进行信息搜索与项目推荐。标签作为用户和项目之间的桥梁，表达了项目的特征以及用户对项目的偏好。知识图谱[7]是一种基于图的数据结构，其节点表示现实世界中存在的实体，边表示实体之间的关系。研究者构建了一系列覆盖不同领域的知识图谱，如 DBpedia[8]、ConceptNet[9]、Freebase[10]、Wikidata[11]等，其中蕴含着丰富的实体和关系信息，扩展了用户与项目之间存在的隐藏关系。知识图谱表示学习能够将知识图谱嵌入到一个低维的向量空间中，利用数值向量反映知识图谱的结构特征。这种方法可以高效地计算实体间的关系，为提高推荐模型的准确性和可解释性提供了有效的方案。

深度学习是机器学习的一个重要分支和研究领域，在数据挖掘、自然语言处理、图像识别等领域取得了突破性的进展[12]。其通过组合低层特征形成更加稠密的高层语义抽象，从而抽取数据的隐含特征表示，近年来在推荐系统中得到了广泛的应用[13]。

为了更好地提供个性化服务，可以从用户标签行为中挖掘和利用隐式反馈信息，以掌握用户偏好。同时，利用知识图谱扩展项目和标签的语义信息及关联关系，补充用户与项目的交互数据。但是，目前融合知识图谱的推荐算法主要集中在项目知识的整合上，而忽略了标签等描述信息在词汇层面丰富的语义知识。因此，本文提出一种基于知识图谱和标签感知的推荐算法（KGTA），利用标签信息和两个不同领域的知识图谱来丰富并挖掘用户和项目的潜在信息，使用深度学习方法来抽取用户和项目的低维、抽象的深层语义特征，并在此基础上进行评分预测。

2 相关工作

2.1 基于深度学习的推荐

深度学习通过学习深层次非线性网络结构，组合低层特征形成更高层的语义抽象，从而自动发现数据的分布式特征表示。基于深度学习的推荐模型利用多层神经网络结构，能够非线性地学习用户与项目的交互信息，获得更深层次、更抽象的隐含特征表示，从而得到较好的推荐效果。深度神经网络（Deep Neural Network，DNN）[14]通过多层隐藏网络学习抽象特征，增强模型的表达能力，在最后的输出层使用得到的抽象特征完成学习任务。Covington 等[15]基于 DNN 的超大规模多分类思想，采取两层深度网络在 YouTube 视频库中实现了高效的个性化推荐。Zhang 等[16]提出了一种协同过滤推荐算法与 DNN 相结合的模型，将特征表示模块捕捉到的潜在特征输入到 DNN 中进行预测评分。循环神经网络（Recurrent Neural Network，RNN）[17]是一种可以处理序列数据的神经网络，其考虑了建模数据之间的序列影响，并由此研究出长短时记忆网络（Long Short-Term Memory，LSTM）[18]，其通过增加保存长期状态的隐层单元，可以更加有效地对长程依赖关系建模。Yang 等[19]提出了一种基于 LSTM 的上下文感知推荐模型，以统一的方式捕获和存储长期稳定兴趣和短期动态兴趣，为用户推荐科学论文。

2.2 基于标签的推荐

随着标签技术的发展，基于标签的推荐算法也在飞速发展。通常，基于标签的推荐系统通过分析用户标注在项目上的标签信息进行推荐。Liang 等[20]将不同标签的权重向量作为输入，通过确定项目的相关标签和用户的标签偏好来进行推荐。Wu 等[21]提出了 Tag2Word 模型来进一步发现标签信息的语义，从而改进推荐方法。深度学习在基于标签的推荐系统中被广泛采用。Zuo 等[22]首先用标签来表示用户特征，然后利用深层神经网络模型从标签的潜在空间中逐层提取深度特征，并将提取的特征用于基于用户的协同过滤推荐。Xu 等[23]提出了 DSPR，利用基于深层语义相似度的神经网络将用户特征和项目特征映射到一个深层特征空间。Liang 等[24]将标签信息与基于深度学习的自然语言处理技术相结合，使用预先训练过的单词嵌入来表示用户定义的标签，由此提取项目和用户的潜在特征。

2.3 基于知识图谱的推荐

知识图谱作为推荐系统中有效的辅助信息来源，蕴含了推荐系统中项目的大量相关信息以及项目之间丰富的隐含语义关联。基于知识图谱的推荐方法可以分为 3 种[7]：基于嵌入的方法、基于路径的方法和两者混合的方法。RippleNet[25]以用户交互的项目为中心构建知识图谱，用户兴趣在知识图谱上向外传播且逐层衰减。知识图谱卷积网络（Knowledge Graph Convolutional Network，KGCN）[26]利用图注意力网络自动捕获知识图谱高阶结构和语义信息，并学习用户潜在的长程兴趣，使得推荐具有较好的可解释性。

近年来，知识图谱与深度学习相结合的推荐方法成为了一种发展趋势，其通过知识图谱表示学习得到知识图谱中实体和关系的低维向量，并利用深度神经网络抽象出项目和用户的隐含特征，提升了推荐性能。DKN[27]提取新闻标题的相关背景知识来构建知识图谱，采用 TranR 方法实现了知识图谱的嵌入，然后将知识图谱的实体向量与词表示向量作为卷积网络的输入以提取新闻特征。RKGE[28]基于深度神经网络，自动挖掘知识图谱中实体之间的连接模式，学习用户和项目之间的关系。K-NCR[29]是一种基于深度神经网

络的知识图谱增强的神经协同推荐方法，自动挖掘并扩展用户潜在兴趣以及知识图谱中实体之间的连接模式。HAGERec[30]利用层次注意图卷积网络，通过双向信息传播策略从知识图谱中学习用户和项目的表示，并通过建立知识感知连接赋予模型可解释性。

基于以上研究，本文将标签信息和知识图谱相结合，主要贡献如下：1)采用面向项目的知识图谱 DBpedia 和面向单词的知识图谱 ConceptNet，分别强化项目和标签的知识信息，充分挖掘项目和用户的低阶与高阶属性，通过 KGCN 得到项目和用户的统一表示；2)分别利用深度神经网络(DNN)和加入注意力机制的双层递归神经网络(RNN)提取项目和用户的潜在特征，并在此基础上进行评分预测；3)在公开数据集 MovieLens 上进行实验，实验结果证明了算法的有效性。

3 基于知识图谱和标签感知的推荐算法

本节具体介绍 KGTA 的详细结构，基于知识图谱和标签感知的推荐算法设计如图 1 所示，包括知识图谱嵌入、用户项目建模和评分预测 3 部分。

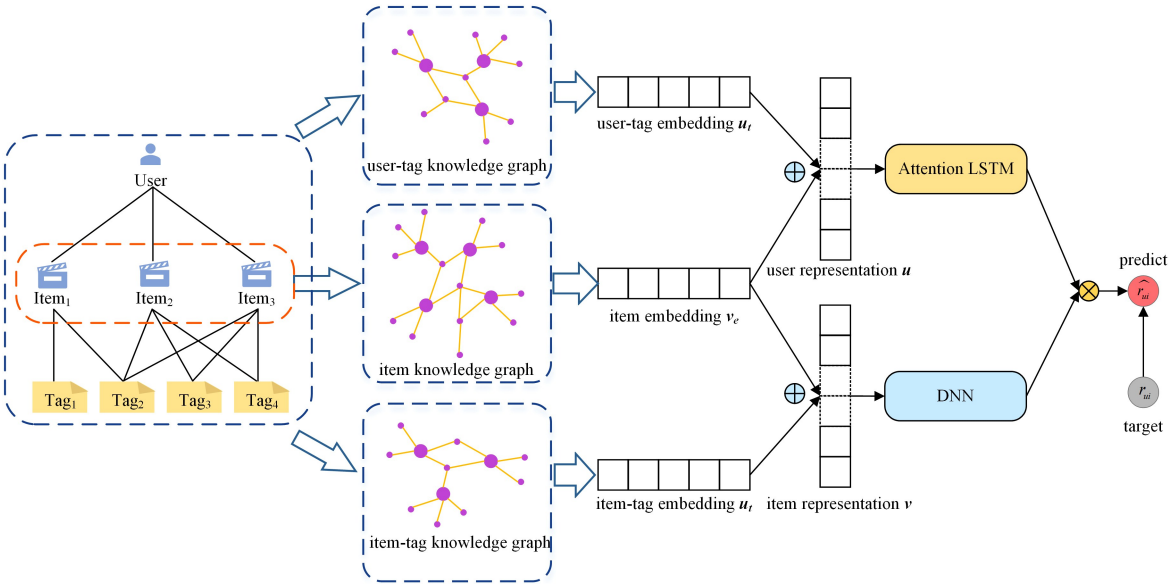

图 1 KGTA 框架图

Fig. 1 KGTA frame diagram

算法以用户、项目以及标签信息为输入，通过知识图谱卷积网络获得用户和项目的特征表示，最终预测用户对项目的评分。

3.1 知识图谱嵌入

知识图谱 G 通常以“实体-关系-实体”的三元组 (h,r,t) 存储实体及其关系，其中 $h\in E, r\in R, t\in E$ 分别代表一个三元组的头结点、关系和尾节点，E 和 R 分别是知识图谱中的实体和关系集合。给定知识图谱中的三元组，知识图谱特征学习的目的是为每个实体和关系学习得到一个低维特征表示，并保留原有知识图谱的结构信息。

3.1.1 项目实体嵌入

项目嵌入反映项目实体的特征，首先将 DBpedia 作为面向项目的知识图谱，构建以项目为中心的知识图谱，再利用 KGCN 对知识图谱进行表示学习，即可得到项目实体表示向量。

KGCN 是应用在知识图谱上的图注意力网络，可用来捕获知识图谱中的拓扑结构以及实体信息。其核心思想是，在计算知识图谱中的一个给定实体的特征时，将其邻居节点的信息有偏见地聚合起来并融入该实体的特征中。该模型是多层结构，低层时可获取实体的低阶特征，高层时可挖掘实体的高阶信息。

对于用户 $u\in U$ 和项目 $v\in V$，其中 U 和 V 分别是用户集合和项目集合。$N(v)$ 表示与 v 直接相连的实体集合，$\boldsymbol{r}_{i,j}$ 表示连接实体 e_i 和实体 e_j 的关系。利用向量内积计算用户与关系的相关性，称其为用户-关系评分：

$$\pi^{u}_{r_{i,j}}=\boldsymbol{u}\cdot\boldsymbol{r}_{i,j} \tag{1}$$

其中，$\boldsymbol{u}\in\mathbb{R}^d$ 和 $\boldsymbol{r}_{i,j}\in\mathbb{R}^d$ 分别是用户 u 和关系 $\boldsymbol{r}_{i,j}$ 的特征表示，d 为特征向量维度。用户关系评分 $\pi^{u}_{r_{i,j}}$ 刻画了关系 $\boldsymbol{r}_{i,j}$ 对用户 u 的重要程度。例如，一个用户可能会对同类型的项目有较大的兴趣，因此，当关系 $\boldsymbol{r}_{i,j}$ 为项目类型时需要给予较高的关注。

然后对项目 v 的近邻拓扑结构进行建模，计算项目 v 的领域节点的线性组合。

$$\boldsymbol{v}^{u}_{N(v)}=\sum_{e\in N(v)}\tilde{\pi}^{u}_{r_{v,e}}\boldsymbol{e}^{0} \tag{2}$$

其中，$\boldsymbol{e}^0\in\mathbb{R}^d$ 为实体 e 的初始表示，$\tilde{\pi}^{u}_{r_{v,e}}$ 为归一化用户-关系评分。

$$\tilde{\pi}^{u}_{r_{v,e}}=\frac{\exp(\pi^{u}_{r_{v,e}})}{\sum_{e\in N(v)}\exp(\pi^{u}_{r_{v,e}})} \tag{3}$$

在计算一个项目的邻域表示时，归一化用户-关系评分体现了用户偏好的权重，根据用户偏好权重对项目的邻域进行加权聚合。

在真实的知识图谱中，不同项目实体 v 的邻域 $N(v)$ 的大小可能存在差异。为了保持计算效率，需要为每个实体从邻居中抽取固定数量的邻域集合作为样本。将项目实体 v 的邻域表示记为 $\boldsymbol{v}^{1}_{S(v)}$，其中 $S(v)\triangleq\{e\mid e\sim N(v)\}$，

$|S(v)|=K$ 为邻居采样数量。

将项目实体的初始表示 $\boldsymbol{v}^0$ 和其邻域表示 $\boldsymbol{v}^1_{S(v)}$ 进行聚合，以获得融合项目实体邻域信息的项目实体表示 $\boldsymbol{v}_{\text{agg}}$：

$$\boldsymbol{v}_{\text{agg}}=\sigma(\boldsymbol{W}_{\text{agg}}\cdot(\boldsymbol{v}^0+\boldsymbol{v}^1_{S(v)})+\boldsymbol{b}_{\text{agg}}) \tag{4}$$

其中，$\boldsymbol{W}_{\text{agg}}\in\mathbb{R}^{d\times 2d}$ 和 $\boldsymbol{b}_{\text{agg}}\in\mathbb{R}^{d}$ 分别为权重和偏置，σ 为激活函数。

通过单层的 KGCN，一个实体的表示会依赖自身及其邻域，称 $\boldsymbol{v}_{\text{agg}}$ 为项目 v 的 1 阶表示，记为 $\boldsymbol{v}^1$。为了更深入、合理地探索用户的潜在兴趣，挖掘实体的高阶特征，将 KGCN 从一层扩展到多层。将每个项目实体的初始表示（即零阶实体表示）向外传播，与其邻域实体的表示聚合，则可获得 1 阶项目实体表示，然后重复上述过程，即进一步聚合 1 阶表示，以获得 2 阶表示。一般来说，一个实体的 L 阶表示是实体自身与其 L 跳范围内的邻域实体的聚合。可将该项目的 L 阶表示作为最终的项目实体表示 $\boldsymbol{v}_e$。KGCN 模型如图 2 所示。

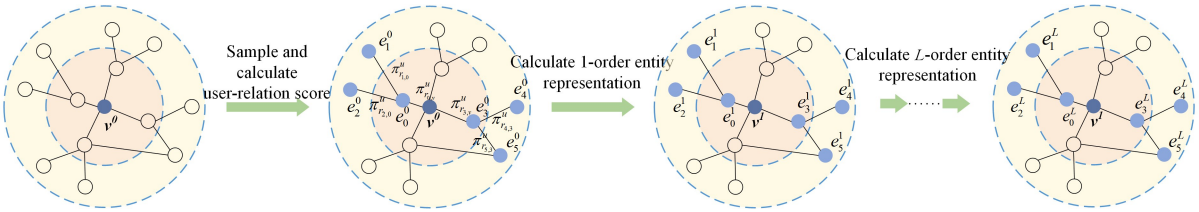

图 2　KGCN 表示学习模型图

Fig. 2　Diagram of KGCN representation learning

首先以项目为中心构建知识图谱；其次对项目的邻域进行采样，并计算用户-关系评分 $\pi^u_{r_{i,j}}$，图 2 中 $\boldsymbol{e}^0_i$ 为实体的初始表示；然后通过式(2)计算实体的 1 阶表示 $\boldsymbol{e}^1_i$；最后将 1 阶表示扩展到 L 层，可获得实体的 L 阶表示 $\boldsymbol{e}^L_i$，并作为实体的最终表示。

3.1.2　标签嵌入

通过使用面向单词的知识图谱 ConceptNet 对标签信息进行增强，扩展标签的语义信息，将标签特征与项目或用户特征进行聚合，挖掘用户和项目相关标签属性更深层次的潜在特征。首先识别标签中的实体，利用实体链接技术（Entity Linking，EL）[31] 消除歧义，与 ConceptNet 知识图谱中的实体进行链接并提取其相关的三元组；然后采用类似项目实体嵌入方法，以标签中的实体为中心构建知识图谱，使用 KGCN 方法获得项目标签 $\boldsymbol{v}_t$ 的表示和用户标签 $\boldsymbol{u}_t$ 的表示。

3.2　项目和用户建模

3.2.1　项目建模

将项目实体嵌入 $\boldsymbol{v}_e$ 与项目标签嵌入 $\boldsymbol{v}_t$ 相聚合，获得最终的项目表示 $\boldsymbol{v}$：

$$\boldsymbol{v}=\boldsymbol{v}_e\oplus\boldsymbol{v}_t \tag{5}$$

其中，$\oplus$ 表示两个向量之间的串联操作。获得的项目特征能更好地揭示项目之间的相似性。

获得项目嵌入后，使用一个深度神经网络来学习项目的潜在特征，将原始项目表示 $\boldsymbol{v}^{(1)}$ 作为输入，通过一个隐含层输出项目的隐表示 $\widetilde{\boldsymbol{I}}_1$：

$$\widetilde{\boldsymbol{I}}_1=g(f(\boldsymbol{v}^{(1)}))=\text{ReLU}(\boldsymbol{W}_1\cdot\boldsymbol{v}^{(1)}+\boldsymbol{b}_1) \tag{6}$$

其中，$\boldsymbol{W}_1$ 是连接输入层和第一个隐含层的权重矩阵，$\boldsymbol{b}_1$ 是偏置，$g(\cdot)$ 是 ReLU 激活函数。以类似的方式，可以得到第 j 层的输出：

$$\widetilde{\boldsymbol{I}}=g(f(\boldsymbol{v}^{(j-1)}))=\text{ReLU}(\boldsymbol{W}_u\cdot\boldsymbol{v}^{(j-1)}+\boldsymbol{b}_u) \tag{7}$$

其中，$\boldsymbol{v}^{(j-1)}$ 是 $(j-1)$ 层的输出，$\widetilde{\boldsymbol{I}}$ 是项目的潜在向量表示。

3.2.2　用户建模

用户特征由根据时间组织的用户交互过的项目实体嵌入 $\boldsymbol{v}_e$ 和用户标签嵌入 $\boldsymbol{u}_t$ 聚合，获得最终的用户表示 $\boldsymbol{u}$：

$$\boldsymbol{u}=\boldsymbol{v}_e\oplus\boldsymbol{u}_t \tag{8}$$

用户特征同时捕获了用户对项目实体的动态偏好和用户对标签属性的偏好，能够更好地表示用户的潜在特征。

为了更好地挖掘用户长短期的潜在兴趣，设计了一个基于注意力 LSTM 结构的神经网络，其中包含 2 个 LSTM 层和注意力层。此模型的整体结构如图 3 所示。

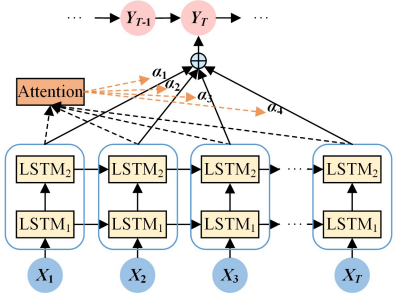

图 3　注意力 LSTM 模型结构图

Fig. 3　Structure of attention LSTM

LSTM 是一个从序列数据中学习特征的强大模型，与普通的神经网络相比，该模型对序列进行逐步分析，通过增加保存长期状态的隐层单元，将之前所有步骤的信息存储在隐层中，可以更加有效地对长程依赖关系建模。LSTM 在每个神经元内部设计遗忘门、输入门和输出门，选用误差函数反馈权重，通过忘记门决定记忆单位能否被清除。

LSTM 的遗忘门、输入门和输出门的计算式如式(9)—式(14)所示：

$$\boldsymbol{f}_t=\sigma(\boldsymbol{W}_f[\boldsymbol{h}_{t-1},\boldsymbol{x}_t]+\boldsymbol{b}_f) \tag{9}$$

$$\boldsymbol{i}_t=\sigma(\boldsymbol{W}_i[\boldsymbol{h}_{t-1},\boldsymbol{x}_t]+\boldsymbol{b}_i) \tag{10}$$

$$\widetilde{\boldsymbol{C}}_t=\tanh(\boldsymbol{W}_{\widetilde{C}}[\boldsymbol{h}_{t-1},\boldsymbol{x}_t]+\boldsymbol{b}_{\widetilde{C}}) \tag{11}$$

$$\boldsymbol{C}_t=\boldsymbol{f}_t*\boldsymbol{C}_{t-1}+\boldsymbol{i}_t*\widetilde{\boldsymbol{C}}_t \tag{12}$$

$$\boldsymbol{o}_t=\sigma(\boldsymbol{W}_o[\boldsymbol{h}_{t-1},\boldsymbol{x}_t]+\boldsymbol{b}_o) \tag{13}$$

$$\boldsymbol{h}_t=\boldsymbol{o}_t*\tanh(\boldsymbol{C}_t) \tag{14}$$

其中，$\boldsymbol{W}_i$，$\boldsymbol{W}_f$，$\boldsymbol{W}_{\widetilde{C}}$ 和 $\boldsymbol{W}_o$ 是权重，$\boldsymbol{b}_i$，$\boldsymbol{b}_f$，$\boldsymbol{b}_{\widetilde{C}}$ 和 $\boldsymbol{b}_o$ 是偏置。根据上一个隐藏层 $\boldsymbol{h}_{t-1}$ 的状态，输入序列 $\boldsymbol{x}_t$ 通过激活函数构成遗忘门 $\boldsymbol{f}_t$。输入门 $\boldsymbol{i}_t$ 和输出门 $\boldsymbol{o}_t$ 也由 $\boldsymbol{x}_t$ 和 $\boldsymbol{h}_{t-1}$ 计算。遗忘门

$\boldsymbol{f}_t$ 与前单元状态 $\boldsymbol{C}_{t-1}$ 联合确定是否丢弃信息。

注意力机制可以用来学习用户的历史数据对预测目标的贡献程度，从而能够有效地反映用户的行为偏好。通过注意力机制计算用户已交互项目的权重，按此权重对交互历史表示进行加权求和，即可获得用户的动态喜好表示。对用户交互历史中的各个项目向量 $\{\boldsymbol{v}_{e,1}, \boldsymbol{v}_{e,2}, \cdots, \boldsymbol{v}_{e,K}\}$ 分配权重并加权平均，以获得用户的动态偏好表示。

$$\widetilde{\boldsymbol{U}} = \sum_{i=1}^{K} \alpha_i \boldsymbol{v}_{e,i} \tag{15}$$

其中，α_i 为注意力权重，其计算方法为：

$$g_i = \tanh(\boldsymbol{W}_{\text{att}} \cdot \boldsymbol{v}_{e,i} + \boldsymbol{b}_{\text{att}}) \tag{16}$$

$$\alpha_i = \frac{\exp(g_i)}{\sum_{j=1}^{K} \exp(g_i)} \tag{17}$$

其中，$\boldsymbol{W}_{\text{att}}$ 和 $\boldsymbol{b}_{\text{att}}$ 为注意力机制的权重和偏置。

3.3 评分预测

利用学习到的用户和项目的潜在特征来预测相应的评分。在矩阵分解法中，用户潜在向量 $\boldsymbol{u}_i$ 和项目潜在向量 $\boldsymbol{v}_j$ 的内积可以近似于 r_{ij}：

$$r_{ij} \approx \boldsymbol{u}_i \cdot \boldsymbol{v}_j \tag{18}$$

因此，可以利用从混合深层结构中学习到的两个潜在特征向量的内积来获得用户对项目的评分预测。

$$\hat{r}_{ui} = pred(\widetilde{\boldsymbol{U}}, \widetilde{\boldsymbol{I}}) = \widetilde{\boldsymbol{U}} \cdot \widetilde{\boldsymbol{I}} \tag{19}$$

损失函数是真实评分和预测评分之间的平方误差，是算法的最小化目标，定义为：

$$L(\theta) = \sum_{r_{ui} \in R} (\hat{r}_{ui} - r_{ui}) + \lambda \parallel \Theta \parallel^2 \tag{20}$$

其中，r_{ui} 是实际评分，超参数 λ 防止过拟合，其通过控制 L_2 正则化的强度来实现，Θ 是要训练的参数集。采用随机梯度下降法来最小化损失函数。该算法是最优化理论中基础的优化算法，首先通过求参数的偏导数找到最速下降方向，然后通过迭代法不断地优化参数。

4 实验及结果分析

在公开数据集上对 KGTA 算法的性能进行评估与验证，与目前较好的推荐模型进行对比，并对实验结果进行相应的分析。

4.1 实验数据集与设置

本文采用 GroupLens 站点提供的 MovieLens 数据集对算法的性能进行测试，该数据集是用于推荐领域的标准数据集，包含 283228 个用户对 58098 部电影的 27753444 个评分和 1108997 个标签。实验前对数据集进行预处理，随机选择有评分和标签的用户创建两个不同规模的数据集。数据集如表 1 所列。

表 1 数据集信息

Table 1 Dataset information

数据集	用户数	电影数	标签数	评分数
MovieLens1	2000	1263	3852	84615
MovieLens2	6000	3161	10429	603728

实验环境为 Intel(R) Core(TM) i7-10510U CPU@2.40 GHz 处理器和 8 GB 内存，Windows10 64 位操作系统，运用 Python 编程语言，通过深度学习框架 TensorFlow 搭建神经网络。

本文采用 5 折交叉验证的方法进行训练和测试，每次随机选取数据集中的 80% 作为训练集，20% 作为测试集，最终综合 5 次实验结果的平均值，得出结果。

4.2 评价指标

本文采用平均绝对值误差（MAE）和均方根误差（RMSE）两个指标对实验结果进行评估。平均绝对值误差是所有项目实际评分和预测评分之间误差的绝对值之和的平均值，它衡量了真实值和预测评分之间的平均差异。均方根误差是所有项目真实评分和预测评分之间误差的平方之和的平均值的根值。*MAE* 和 *RMSE* 的定义分别如下：

$$MAE = \frac{\sum_{r_{ui} \in R} |\hat{r}_{ui} - r_{ui}|}{|R|} \tag{21}$$

$$RMSE = \sqrt{\frac{\sum_{r_{ui} \in R} (\hat{r}_{ui} - r_{ui})^2}{|R|}} \tag{22}$$

其中，$|R|$ 为需要预测的项目集合，$\hat{r}_{ui}$ 和 r_{ui} 分别为用户 u_i 对项目 v_j 的预测评分和真实评分。*MAE* 和 *RMSE* 的值越小，结果就越准确。

4.3 实验结果与分析

4.3.1 模型结构对算法的影响

为了评估选择不同网络类型和不同网络深度时算法的性能，本文采用自下而上的方法创建不同的模型进行比较。算法中，λ 设置为 0.01，学习率为 0.01，嵌入维度为 100 维。其他参数参考文献[24]，通过在数据集上实验所确定的三层神经网络的最佳参数进行设置。

模型 1 分别使用三层 DNN 和单层 LSTM 学习项目和用户的潜在特征；

模型 2 分别使用三层 DNN 和双层 LSTM 学习项目和用户的潜在特征；

模型 3 分别使用三层 DNN 和加入注意力机制的双层 LSTM 学习项目和用户的潜在特征。

不同结构对算法的影响如表 2 所列。

表 2 不同结构对算法的影响

Table 2 Influence of different structures on algorithm

Model	MovieLens1		MovieLens2	
	MAE	*RMSE*	*MAE*	*RMSE*
模型 1	0.834	1.075	0.684	0.901
模型 2	0.810	0.986	0.668	0.875
模型 3	**0.783**	**0.962**	**0.653**	**0.864**

由实验结果可知，使用 DNN 和双层 LSTM 的模型 2 的 *MAE* 值和 *RMSE* 值比模型 1 低，表明双层 LSTM 结构会对算法性能产生积极影响。因为低层神经网络捕获的是输入数据的表面特征，而更深层的神经网络可以抽取更高层的语义抽象，得到数据的隐含特征表示。在双层 LSTM 结构的基础上，加入注意力机制的模型 3 比模型 2 表现更好，表明注意力机制可以从用户的交互数据中学习用户对项目的偏好权重，反映用户的兴趣，从而提高推荐性能。本文提出的具有注意力机制的双层 LSTM 结构能够通过潜在特征的深度交互来学习数据中复杂的非线性关系，表现出了较好的推荐效果。

4.3.2 嵌入维度对算法的影响

知识图谱表示学习是将知识图谱嵌入一个低维的空间

中，不同的嵌入维度所取得的推荐效果也会有所不同。针对项目实体和标签嵌入的维度，在模型 3 的基础上，分别选取 50～250 维进行实验，实验结果如图 4 所示。

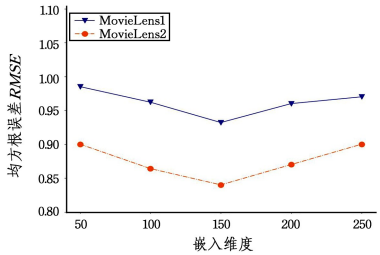

图 4　不同嵌入维度下算法的 *RMSE*

Fig. 4　*RMSE* of different embedding dimensions

从实验结果可以看出，随着知识图谱表示学习的嵌入维度的增加，本文算法的均方根误差(RMSE)先呈下降趋势，当嵌入维度为 150 维时，*RMSE* 值最低，然后随着嵌入维度的增加，*RMSE* 值升高。算法的嵌入维度增加更能表达用户和项目之间的深层特征，模型更加拟合，推荐效果也更好；但当嵌入维度增加到一定程度时，对训练集中用户和项目的特征表示过于细致，使得算法过拟合，预测效果变差。因此，当嵌入维度为 150 维时，推荐效果最好。

4.3.3　与其他算法的对比

为了验证本文算法 KGTA 的有效性，将其与 4 种算法进行实验对比，包括标签感知的推荐算法和与知识图谱相结合的推荐算法。对比算法的描述如下。

(1)DSPR[23]：将基于标签的用户和项目信息作为两个神经网络的输入，利用深层神经网络捕获用户和项目的相关性。

(2)TRSDL[24]：使用预先训练的单词嵌入表示用户标签，利用 DNN 和 RNN 分别提取项目和用户的潜在特征进行预测。

(3)CKE[32]：使用基于协同过滤结合知识图谱嵌入的方法，通过单一知识图谱学习项目和用户表示。

(4)RKGE[28]：利用知识图谱编码的异构信息，采用递归网络结构学习用户和项目之间的关系。

表 3 列出了不同算法在两个数据集上的实验结果。

表 3　各算法在不同数据集上的实验结果

Table 3　Result of algorithms on different datasets

Model	MovieLens1		MovieLens2	
	MAE	*RMSE*	*MAE*	*RMSE*
DSPR	0.9137	1.1134	0.7061	0.9223
TRSDL	0.8591	1.0856	0.6634	0.9065
CKE	0.8014	1.0659	0.6502	0.8901
RKGE	0.7632	0.9734	0.6368	0.8612
KGTA	**0.7460**	**0.9322**	**0.6046**	**0.8503**

从表 3 可以看出，TRSDL 比 DSPR 的预测性能好，因为前者在提取基于标签的用户潜在特征时考虑了时间因素，通过循环神经网络捕获了用户的长短期潜在偏好。CKE 和 RKGE 也表现出了较好的性能，两者都利用单一的知识图谱对用户的交互历史构建用户的表示，然后计算图谱中的实体与待推荐项目之间的相关性，说明这些模型可以利用知识图谱增强用户项目信息，从而进行有效的推荐。相比 CKE，RGKE 考虑到了路径连接的实体之间的语义关系，使用循环网络对实体语义路径进行建模，从而为实体和实体关系的表示提供了统一的学习方法，提升了推荐性能；同时，从另一方面说明 CKE 利用 TransR 等方法训练实体表示的方法不能很好地利用知识图谱的信息。本文提出的 KGTA 算法在两个数据集上的表现均优于其他模型，这证明了该算法的有效性。KGTA 算法将标签信息与知识图谱相结合，采用面向项目和面向单词的知识图谱分别强化项目和标签的知识，并通过深层结构挖掘用户和项目更深层次的潜在特征；同时，可以看出，本文设计加入注意力机制的双层 LSTM 在模型中发挥了积极作用，提高了预测准确性。

结束语　本文提出了一种基于知识图谱和标签感知的推荐算法，既利用了项目本身内在的语义信息，又结合了用户标签信息，能够更加全面地考虑项目和用户的属性。同时，该算法使用两个知识图谱增强项目和用户标签的语义信息，通过知识图谱卷积网络捕获低阶与高阶特征，并通过本文设计的深层神经网络结构挖掘用户和项目更高层次的潜在特征，实验结果验证了本文算法的有效性。但本文算法依赖于开源的知识图谱且没有考虑到知识图谱的动态性，导致算法具有一定的领域限制；另外，算法没有考虑用户交互项目更细致的信息以及社交关系和评论等辅助信息。在未来的工作中，将尝试融合多源异构辅助信息，并通过扩展嵌入技术和深度学习方法进一步提升算法的推荐性能。

参 考 文 献

[1] DAVID R, JOHN G, JOHN R. Data age 2025: the digitization of the world from edge to core[EB/OL]. [2019-05-12]. https://www.seagate.com/cn/zh/our-story/data-age-2025.

[2] HUANG L W, JIANG B T, LU S Y, et al. Review of recommendation systems based on deep learning[J]. Chinese Journal of Computers, 2018, 41(7): 1619-1647.

[3] BOBADILLA J, ORTEGA F, HERNANDO A, et al. Recommender systems survey[J]. Knowledge-Based Systems, 2013, 46: 109-132.

[4] INUZUKA K, HAYASHI T, TAKAGI T. Recommendation System Based on Prediction of User Preference Changes[C]// 2016 IEEE/WIC/ACM International Conference on Web Intelligence (WI). IEEE, 2016: 192-199.

[5] SHEN J, QIAO S J, HAN N, et al. Personalized Recommendation Model with Multiple Information Fusion[J]. Journal of Chongqing University of Technology (Natural Science), 2021, 35(3): 128-138.

[6] XIANG L. Practice of Recommendation System [M]. Posts & Telecom Press, 2012.

[7] LIU Q, LI Y, DUAN H, et al. Knowledge Graph Construction Techniques[J]. Journal of Computer Research and Development, 2016, 53(3): 582-600.

[8] LEHMANN J, ISELE R, JAKOB M, et al. Dbpedia-a large-scale, multilingual knowledge base extracted from wikipedia[J]. Semantic web, 2015, 6(2): 167-195.

[9] SPEER R, CHIN J, HAVASI C. ConceptNet 5.5: An Open Multilingual Graph of General Knowledge[C]// Thirty-first

AAAI conference on artificial intelligence. 2017:4444-4451.

[10] BERANT J, CHOU A, FROSTIG R, et al. Semantic parsing on freebase from question-answer pairs[C]// Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing. 2013:1533-1544.

[11] VRANDEČIĆ D, KRÖTZSCH M. Wikidata: A Free Collaborative Knowledgebase[J]. Communications of the ACM, 2014, 57(10):78-85.

[12] FU W B, SUN T, LIANG J, et al. Review of Principle and Application of Deep Learning[J]. Computer Science, 2018, 45(S1): 11-15.

[13] DA'U A, SALIM N. Recommendation system based on deep learning methods: a systematic review and new directions[J]. Artificial Intelligence Review, 2020, 53(4):2709-2748.

[14] HINTON G E, SALAKHUTDINOV R R. Reducing the Dimensionality of Data with Neural Networks[J]. Science, 2006, 313(5786):504-507.

[15] COVINGTON P, ADAMS J, SARGIN E. Deep Neural Networks for YouTube Recommendations[C]// Proceedings of the 10th ACM Conference on Recommender Systems. 2016: 191-198.

[16] ZHANG L, LUO T, ZHANGA F, et al. A Recommendation Model Based on Deep Neural Network[J]. IEEE Access, 2018, 6:9454-9463.

[17] RUMELHART D, HINTON G, WILLIAMS R. Learning Representations by Back Propagating Errors[J]. Nature, 1986, 323(6088):533-536.

[18] ZHOU Y, HUANG C, HU Q, et al. Personalized learning full-path recommendation model based on LSTM neural networks [J]. Information Sciences, 2018, 444:135-152.

[19] YANG L, ZHENG Y, CAI X, et al. A LSTM based Model for Personalized Context-Aware Citation Recommendation [J]. IEEE Access, 2018, 6:59618-59627.

[20] LIANG H, XU Y, LI Y, et al. Connecting users and items with weighted tags for personalized item recommendations[C]// Proceedings of the 21st ACM conference on Hypertext and hypermedia. 2010:51-60.

[21] WU Y, YAO Y, XU F, et al. Tag2Word: Using Tags to Generate Words for Content Based Tag Recommendation[C]// Proceedings of the 25th ACM International on Conference on Information and Knowledge Management. 2016:2287-2292.

[22] ZUO Y, ZENG J, GONG M, et al. Tag-Aware Recommender Systems Based on Deep Neural Networks[J]. Neurocomputing, 2016, 204:51-60.

[23] XU Z, LUKASIEWICZ T, CHEN C, et al. Tag-Aware Personalized Recommendation Using a Hybrid Deep Model[C]// International Joint Conferences on Artificial Intelligence. AAAI Press, 2017:3196-3202.

[24] LIANG N, ZHENG H, CHEN J, et al. TRSDL: Tag-Aware Recommender System Based on Deep Learning-Intelligent Computing Systems[J]. Applied Sciences, 2018, 8(5):799.

[25] WANG H, ZHANG F, WANG J, et al. Ripple Network: Propagating User Preferences on the Knowledge Graph for Recommender Systems[C]// Proceedings of the 27th ACM International Conference on Information and Knowledge Management. 2018:417-426.

[26] WANG H, ZHAO M, XIE X, et al. Knowledge Graph Convolutional Networks for Recommender Systems[C]// The World Wide Web Conference (WWW'19). 2019:3307-3313.

[27] WANG H, ZHANG F, XIE X, et al. DKN: Deep Knowledge-Aware Network for News Recommendation[C]// Proceedings of the 2018 world wide web conference. 2018:1835-1844.

[28] SUN Z, YANG J, ZHANG J, et al. Recurrent Knowledge Graph Embedding for Effective Recommendation[C]// Proceedings of the 12th ACM Conference on Recommender Systems. 2018:297-305.

[29] SANG L, XU M, QIAN S, et al. Knowledge graph enhanced neural collaborative recommendation[J]. Expert Systems with Applications, 2020, 164:113992.

[30] YANG Z, DONG S. HAGERec: Hierarchical Attention Graph Convolutional Network Incorporating Knowledge Graph for Explainable Recommendation [J]. Knowledge-Based Systems, 2020, 204:106194.

[31] SIL A, YATES A. Re-Ranking for Joint Named-Entity Recognition and Linking[C]// Proceedings of the 22nd ACM International Conference on Information & Knowledge Management. 2013:2369-2374.

[32] 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. 2016:353-362.

NING Ze-fei, born in 1995, postgraduate, is a member of China Computer Federation. His main research interests include recommendation system and data mining.

SUN Jing-yu, born in 1975, Ph.D, associate professor, is a member of China Computer Federation. His main research interests include collaborative web search, recommendation system and smart city.