



(12) 发明专利申请

(10) 申请公布号 CN 115375382 A

(43) 申请公布日 2022. 11. 22

(21) 申请号 202110539784.5

(22) 申请日 2021.05.18

(71) 申请人 京东科技控股股份有限公司

地址 100000 北京市大兴区北京经济技术
开发区科创十一街18号C座2层221室

(72) 发明人 孙冰 陈蒙

(74) 专利代理机构 北京集佳知识产权代理有限
公司 11227

专利代理师 张春辉

(51) Int.Cl.

G06Q 30/06 (2012.01)

G06F 16/36 (2019.01)

G06F 16/9535 (2019.01)

G06F 16/9536 (2019.01)


权利要求书2页 说明书13页 附图4页

(54) 发明名称

一种商品推荐方法、装置及相关设备

(57) 摘要

本申请公开了一种商品推荐方法,包括确定目标用户;从整体协同知识图中获取目标用户对应的目标协同知识图;其中,整体协同知识图根据历史交互信息和商品边信息构建获得;利用预设商品推荐模型对目标协同知识图进行处理,获得目标协同知识图中各商品的推荐值;其中,预设商品推荐模型根据整体协同知识图构建获得;将推荐值超出预设阈值的商品推荐给目标用户;该方法通过将历史交互信息与商品边信息相结合构建用户与商品之间的联系,同时利用商品推荐模型实现动态的商品推荐,极大地提高了商品推荐的精确度和成功率,可以更为有效地满足用户需求,提高用户体验。本申请还公开了一种商品推荐装置、系统以及计算机可读存储介质,均具有上述有益效果。



1. 一种商品推荐方法,其特征在于,包括:

确定目标用户;

从整体协同知识图中获取所述目标用户对应的目标协同知识图;其中,所述整体协同知识图根据历史交互信息和商品边信息构建获得;

利用预设商品推荐模型对所述目标协同知识图进行处理,获得所述目标协同知识图中各商品的推荐值;其中,所述预设商品推荐模型根据所述整体协同知识图构建获得;

将所述推荐值超出预设阈值的商品推荐给所述目标用户。

2. 根据权利要求1所述的推荐方法,其特征在于,所述整体协同知识图的构建过程包括:

根据所述历史交互信息构建用户与商品的二分图;

根据所述商品边信息构建商品知识图谱;

利用预设实体对齐集将所述二分图和所述商品知识图谱进行集成,获得所述整体协同知识图。

3. 根据权利要求1所述的推荐方法,其特征在于,所述预设商品推荐模型的构建过程包括:

提取所述整体协同知识图中的各三元组,并利用各所述三元组构建初始商品推荐模型;

对所述整体协同知识图中的各实体进行向量转化,获得各所述实体对应的嵌入向量;

根据所述三元组中各实体对应的嵌入向量对所述三元组进行可信性计算,获得各所述三元组的可信度;

利用各所述可信度对所述初始商品推荐模型进行优化,获得所述预设商品推荐模型。

4. 根据权利要求1所述的推荐方法,其特征在于,所述利用预设商品推荐模型对所述目标协同知识图进行处理,获得所述目标协同知识图中各商品的推荐值,包括:

对所述目标协同知识图中的各实体进行向量转化,获得各所述实体对应的嵌入向量;

从所述目标协同知识图中提取目标用户实体作为头实体的第一三元组,并利用所述第一三元组中各实体对应的嵌入向量对所述第一三元组进行计算,获得所述目标用户实体对应的第一网络传播结果;

从所述目标协同知识图中提取各商品实体作为头实体的第二三元组,并利用所述第二三元组中各实体对应的嵌入向量对所述第二三元组进行计算,获得各所述商品实体对应的第二网络传播结果;

计算所述第一网络传播结果与各所述第二网络传播结果的内积,获得各所述商品的推荐值。

5. 根据权利要求4所述的推荐方法,其特征在于,所述利用所述第一三元组中各实体对应的嵌入向量对所述第一三元组进行计算,获得所述目标用户实体对应的第一网络传播结果,包括:

根据各所述第一三元组中尾实体对应的嵌入向量计算获得所述目标用户实体在各网络传播层的加权线性组合结果;

将所述目标用户实体对应的嵌入向量与所述加权线性组合结果进行信息聚合,获得各所述网络传播层的聚合结果;

对各所述网络传播层的聚合结果进行连接,获得所述第一网络传播结果。

6.根据权利要求5所述的商品推荐方法,其特征在于,所述根据各所述第一三元组中尾实体对应的嵌入向量计算获得所述目标用户实体在各网络传播层的加权线性组合结果,包括:

利用神经网络注意力机制对各所述第一三元组中尾实体对应的嵌入向量进行加权平均计算,获得所述目标用户实体在各所述网络传播层的加权线性组合结果。

7.根据权利要求1所述的商品推荐方法,其特征在于,还包括:

更新所述历史交互信息和/或所述商品边信息;

利用更新后的历史交互信息和/或商品边信息对所述整体协同知识图进行更新,获得更新后的整体协同知识图;

利用所述更新后的整体协同知识图对所述预设商品推荐模型进行更新。

8.一种商品推荐装置,其特征在于,包括:

目标用户确定模块,用于确定目标用户;

目标协同知识图获取模块,用于从整体协同知识图中获取所述目标用户对应的目标协同知识图;其中,所述整体协同知识图根据历史交互信息和商品边信息构建获得;

商品推荐值计算模块,用于利用预设商品推荐模型对所述目标协同知识图进行处理,获得所述目标协同知识图中各商品的推荐值;其中,所述预设商品推荐模型根据所述整体协同知识图构建获得;

商品推荐模块,用于将所述推荐值超出预设阈值的商品推荐给所述目标用户。

9.一种商品推荐系统,其特征在于,包括:

存储器,用于存储计算机程序;

处理器,用于执行所述计算机程序时实现如权利要求1至7任一项所述的商品推荐方法的步骤。

10.一种计算机可读存储介质,其特征在于,所述计算机可读存储介质中存储有计算机程序,所述计算机程序被处理器执行时用以实现如权利要求1至7任一项所述的商品推荐方法的步骤。

一种商品推荐方法、装置及相关设备

技术领域

[0001] 本申请涉及计算机技术领域,特别涉及一种商品推荐方法,还涉及一种商品推荐装置、系统以及计算机可读存储介质。

背景技术

[0002] 随着电子商务的兴起,电商平台在商品销售领域中占有非常重要的地位,电商平台相较于传统实体商店具备的一个明显优点就是同时展示、销售的商品种类不受限制。但是,由于电商平台上可选择的商品过多,反而会给用户在寻找商品时带来烦恼。为此,很多电商平台会主动向用户推荐商品,用户若对推荐的商品感兴趣,便可快速进入购买环节,不仅为用户提供了购物便利,而且增加了电商平台的销售业绩。

[0003] 目前,商品推荐的方法一般是通过用户历史搜索过的关键词或商品信息在电商平台的数据库中检索,把检索到的商品作为推荐商品推荐给用户。然而,由于电商平台使用的检索服务一般是基于商品的分类搭建的,很容易导致最后推荐给用户的商品是该用户以往购买过的商品,但对于普通用户来说再次购买这些商品的可能性较低,导致商品推荐的精确度和成功率也相对较低。

[0004] 因此,如何有效地提高商品推荐的精确度和成功率是本领域技术人员亟待解决的问题。

发明内容

[0005] 本申请的目的是提供一种商品推荐方法,该商品推荐方法极大地提高了商品推荐的精确度和成功率,可以更为有效地满足用户需求,提高用户体验;本申请的另一目的是提供一种商品推荐装置、系统以及计算机可读存储介质,也具有上述有益效果。

[0006] 第一方面,本申请提供了一种商品推荐方法,包括:

[0007] 确定目标用户;

[0008] 从整体协同知识图中获取所述目标用户对应的目标协同知识图;其中,所述整体协同知识图根据历史交互信息和商品边信息构建获得;

[0009] 利用预设商品推荐模型对所述目标协同知识图进行处理,获得所述目标协同知识图中各商品的推荐值;其中,所述预设商品推荐模型根据所述整体协同知识图构建获得;

[0010] 将所述推荐值超出预设阈值的商品推荐给所述目标用户。

[0011] 优选的,所述整体协同知识图的构建过程包括:

[0012] 根据所述历史交互信息构建用户与商品的二分图;

[0013] 根据所述商品边信息构建商品知识图谱;

[0014] 利用预设实体对齐集将所述二分图和所述商品知识图谱进行集成,获得所述整体协同知识图。

[0015] 优选的,所述预设商品推荐模型的构建过程包括:

[0016] 提取所述整体协同知识图中的各三元组,并利用各所述三元组构建初始商品推荐

模型;

[0017] 对所述整体协同知识图中的各实体进行向量转化,获得各所述实体对应的嵌入向量;

[0018] 根据所述三元组中各实体对应的嵌入向量对所述三元组进行可信性计算,获得各所述三元组的可信度;

[0019] 利用各所述可信度对所述初始商品推荐模型进行优化,获得所述预设商品推荐模型。

[0020] 优选的,所述利用预设商品推荐模型对所述目标协同知识图进行处理,获得所述目标协同知识图中各商品的推荐值,包括:

[0021] 对所述目标协同知识图中的各实体进行向量转化,获得各所述实体对应的嵌入向量;

[0022] 从所述目标协同知识图中提取目标用户实体作为头实体的第一三元组,并利用所述第一三元组中各实体对应的嵌入向量对所述第一三元组进行计算,获得所述目标用户实体对应的第一网络传播结果;

[0023] 从所述目标协同知识图中提取各商品实体作为头实体的第二三元组,并利用所述第二三元组中各实体对应的嵌入向量对所述第二三元组进行计算,获得各所述商品实体对应的第二网络传播结果;

[0024] 计算所述第一网络传播结果与各所述第二网络传播结果的内积,获得各所述商品的推荐值。

[0025] 优选的,所述利用所述第一三元组中各实体对应的嵌入向量对所述第一三元组进行计算,获得所述目标用户实体对应的第一网络传播结果,包括:

[0026] 根据各所述第一三元组中尾实体对应的嵌入向量计算获得所述目标用户实体在各网络传播层的加权线性组合结果;

[0027] 将所述目标用户实体对应的嵌入向量与所述加权线性组合结果进行信息聚合,获得各所述网络传播层的聚合结果;

[0028] 对各所述网络传播层的聚合结果进行连接,获得所述第一网络传播结果。

[0029] 优选的,所述根据各所述第一三元组中尾实体对应的嵌入向量计算获得所述目标用户实体在各网络传播层的加权线性组合结果,包括:

[0030] 利用神经网络注意力机制对各所述第一三元组中尾实体对应的嵌入向量进行加权平均计算,获得所述目标用户实体在各所述网络传播层的加权线性组合结果。

[0031] 优选的,所述商品推荐方法还包括:

[0032] 更新所述历史交互信息和/或所述商品边信息;

[0033] 利用更新后的历史交互信息和/或商品边信息对所述整体协同知识图进行更新,获得更新后的整体协同知识图;

[0034] 利用所述更新后的整体协同知识图对所述预设商品推荐模型进行更新。

[0035] 第二方面,本申请还公开了一种商品推荐装置,包括:

[0036] 目标用户确定模块,用于确定目标用户;

[0037] 目标协同知识图获取模块,用于从整体协同知识图中获取所述目标用户对应的目标协同知识图;其中,所述整体协同知识图根据历史交互信息和商品边信息构建获得;

[0038] 商品推荐值计算模块,用于利用预设商品推荐模型对所述目标协同知识图进行处理,获得所述目标协同知识图中各商品的推荐值;其中,所述预设商品推荐模型根据所述整体协同知识图构建获得;

[0039] 商品推荐模块,用于将所述推荐值超出预设阈值的商品推荐给所述目标用户。

[0040] 第三方面,本申请还公开了一种商品推荐系统,包括:

[0041] 存储器,用于存储计算机程序;

[0042] 处理器,用于执行所述计算机程序以实现如上所述的任一种商品推荐方法的步骤。

[0043] 第四方面,本申请还公开了一种计算机可读存储介质,所述计算机可读存储介质中存储有计算机程序,所述计算机程序被处理器执行时用以实现如上所述的任一种商品推荐方法的步骤。

[0044] 本申请所提供的一种商品推荐方法,包括确定目标用户;从整体协同知识图中获取所述目标用户对应的目标协同知识图;其中,所述整体协同知识图根据历史交互信息和商品边信息构建获得;利用预设商品推荐模型对所述目标协同知识图进行处理,获得所述目标协同知识图中各商品的推荐值;其中,所述预设商品推荐模型根据所述整体协同知识图构建获得;将所述推荐值超出预设阈值的商品推荐给所述目标用户。

[0045] 可见,本申请所提供的商品推荐方法,利用各用户与各商品之间的历史交互信息以及各商品的边信息构建协同知识图,并利用预设商品推荐模型对目标用户对应的目标协同知识图进行分析处理,从而在目标协同知识图中确定推荐值超出预设阈值的商品向目标用户进行商品推荐,由此可见,通过将历史交互信息与商品边信息相结合构建用户与商品之间的联系,同时利用商品推荐模型实现动态的商品推荐,极大地提高了商品推荐的精确度和成功率,从而可以更为有效地满足用户需求,提高用户体验。

[0046] 本申请所提供的一种商品推荐装置、系统以及计算机可读存储介质,均具有上述有益效果,在此不再赘述。

附图说明

[0047] 为了更清楚地说明现有技术和本申请实施例中的技术方案,下面将对现有技术和本申请实施例描述中需要使用的附图作简要的介绍。当然,下面有关本申请实施例的附图描述的仅仅是本申请中的一部分实施例,对于本领域普通技术人员来说,在不付出创造性劳动的前提下,还可以根据提供的附图获得其他的附图,所获得的其他附图也属于本申请的保护范围。

[0048] 图1为本申请所提供的一种商品推荐方法的流程示意图;

[0049] 图2为本申请所提供的一种整体协同知识图的构建方法的流程示意图;

[0050] 图3为本申请所提供的一种商品推荐系统中的实体交互关系图;

[0051] 图4为本申请所提供的一种预设商品推荐模型的构建方法的流程示意图;

[0052] 图5为本申请所提供的一种预设商品推荐模型的框架图;

[0053] 图6为本申请所提供的一种商品推荐装置的结构示意图;

[0054] 图7为本申请所提供的一种商品推荐系统的结构示意图;

[0055] 图8为本申请所提供的一种商品推荐系统的具体结构示意图。

具体实施方式

[0056] 本申请的核心是提供一种商品推荐方法,该商品推荐方法极大地提高了商品推荐的精确度和成功率,可以更为有效地满足用户需求,提高用户体验;本申请的另一核心是提供一种商品推荐装置、系统以及计算机可读存储介质,也具有上述有益效果。

[0057] 为了对本申请实施例中的技术方案进行更加清楚、完整地描述,下面将结合本申请实施例中的附图,对本申请实施例中的技术方案进行介绍。显然,所描述的实施例仅仅是本申请一部分实施例,而不是全部的实施例。基于本申请中的实施例,本领域普通技术人员在没有做出创造性劳动前提下所获得的所有其他实施例,都属于本申请保护的范围。

[0058] 相关技术中,商品推荐的方法一般是通过用户历史搜索过的关键词或商品信息在电商平台的数据库中检索,把检索到的商品作为推荐商品推荐给用户。然而,由于电商平台使用的检索服务一般是基于商品的分类搭建的,很容易导致最后推荐给用户的商品是该用户以往购买过的商品,但对于普通用户来说再次购买这些商品的可能性较低,导致商品推荐的精确度和成功率也相对较低。因此,本申请提供了一种商品推荐方法,以有效克服上述技术问题。

[0059] 本申请实施例提供了一种商品推荐方法。

[0060] 请参考图1,图1为本申请所提供的一种商品推荐方法的流程示意图,该商品推荐方法可包括:

[0061] S101:确定目标用户;

[0062] 本步骤旨在实现目标用户的确定,该目标用户即为需要进行商品推荐的用户。具体而言,当用户登录系统进行商品查询或购买时,系统即可向该用户进行商品推荐,也就是说,目标用户即为登录系统的各个用户,系统则可以通过登录请求确定目标用户。

[0063] S102:从整体协同知识图中获取目标用户对应的目标协同知识图;其中,整体协同知识图根据历史交互信息和商品边信息构建获得;

[0064] 本步骤旨在实现目标用户对应的目标协同知识图的获取,该目标协同知识图从整体协同知识图中提取获得,该整体协同知识图基于各个用户与各个商品之间的历史交互信息以及各个商品的边信息构建获得。

[0065] 其中,历史交互信息是指用户与商品之间已经发生过的交互信息,如某用户购买过某商品或者某用户点击浏览过某商品等信息,可以理解的是,该历史交互信息可以涵盖系统内所有用户与所有商品之间的交互信息,以便于构建更为全面具体的整体协同知识图,进而提高商品推荐的精确度。

[0066] 其中,商品边信息是指系统内各商品的属性信息以及各商品与其他实体之间的关系,属性信息可以包括但不限于商品的所属品牌、生产产地、上市时间、商品类型、购买人群等,商品与其他实体之间的关系可以包括但不限于商与用户之间的关系、商品与商品品牌之间的关系、商品与其他商品之间的关系等。此外,当用户登录系统时未必已经知道自己的偏好,他们可能是在点击浏览商品中确定首选项,也可能是在和客服的对话中表达自己的偏好,这些偏好很多也属于商品属性信息。

[0067] 其中,协同知识图(Collaborative Knowledge Graph,CKG)是指用于揭示实体之间关系的语义网络,整体协同知识图则是指用于表示系统内各实体之间关系的语义网络,系统内实体具体可以为登录系统的各个用户、系统内展示的各个商品以及各类商品品牌

等,因此,整体协同知识图可以基于系统内的历史交互信息以及商品边信息构建生成。进一步,目标协同知识图则是对应于目标用户的协同知识图,具体为包括有该目标用户与系统内其他实体之间关系的语义网络,因此,在确定目标用户后,可以根据该目标用户直接从整体协同知识图中提取获得。

[0068] S103:利用预设商品推荐模型对目标协同知识图进行处理,获得目标协同知识图中各商品的推荐值;其中,预设商品推荐模型根据整体协同知识图构建获得;

[0069] S104:将推荐值超出预设阈值的商品推荐给目标用户。

[0070] 以上步骤旨在实现商品推荐值的计算进而完成商品推荐。具体而言,可以利用预设商品推荐模型对目标协同知识图进行分析处理,获得目标协同知识图中所涉及到的各商品相对于目标用户的推荐值,当推荐值超出预设阈值时,说明目标用户购买该商品的可能性较大,此时,则可以将该商品推荐给目标用户,反之,若推荐值未超出预设阈值,则说明目标用户购买该商品的可能性较小,此时无需将该商品推荐给目标用户,由此即可通过计算目标协同知识图中各商品的推荐值实现商品推荐。可以理解的是,预设阈值的具体取值并不影响本技术方案的实施,可以由技术人员根据实际情况进行设定,本申请对此不做限定。

[0071] 其中,预设商品推荐模型是预先利用整体协同知识图构建获得的网络模型,在商品推荐过程中可以直接调取使用。由于整体协同知识图基于系统内的历史交互信息以及商品边信息构建生成,包括有系统内的各类数据信息,因此,基于整体协同知识图构建预设商品推荐模型可以更为有效地保证模型精度,从而实现更为准确的商品推荐。

[0072] 可以理解的是,在系统运行过程中,系统内的数据信息是实时变化的,如可能会实时产生新的历史交互数据,以及增加或减少或变更商品边信息等,而这些实时变化的数据信息可以作为更新信息用以更新预设商品推荐模型,以提高模型精度,进一步提高商品推荐结果的准确性。

[0073] 因此,作为一种优选实施例,该商品推荐方法还可以包括:更新历史交互信息和/或商品边信息;利用更新后的历史交互信息和/或商品边信息对整体协同知识图进行更新,获得更新后的整体协同知识图;利用更新后的整体协同知识图对预设商品推荐模型进行更新。

[0074] 具体而言,可以对历史交互信息和/或商品边信息进行更新,由于整体协同知识图基于系统内的历史交互信息以及商品边信息构建生成,预设商品推荐模型基于整体协同知识图构建获得,因此,可以利用更新后的历史交互信息和/或商品边信息对整体协同知识图进行更新,进而利用更新后的整体协同知识图对预设商品推荐模型进行更新。其中,更新操作可以设为定时更新,即按照预设时间间隔进行一次模型更新,当然,该预设时间间隔的具体取值并不影响本技术方案的实施,可以由技术人员根据实际情况进行设定,本申请对此不做限定。

[0075] 可见,本申请所提供的商品推荐方法,利用各用户与各商品之间的历史交互信息以及各商品的边信息构建协同知识图,并利用预设商品推荐模型对目标用户对应的目标协同知识图进行分析处理,从而在目标协同知识图中确定推荐值超出预设阈值的商品向目标用户进行商品推荐,由此可见,通过将历史交互信息与商品边信息相结合构建用户与商品之间的联系,同时利用商品推荐模型实现动态的商品推荐,极大地提高了商品推荐的精确度和成功率,从而可以更为有效地满足用户需求,提高用户体验。

[0076] 在上述实施例的基础上：

[0077] 本申请实施例提供了一种整体协同知识图的构建方法。

[0078] 请参考图2,图2为本申请所提供的一种整体协同知识图的构建方法的流程示意图,该方法可以包括：

[0079] S201:根据历史交互信息构建用户与商品的二分图；

[0080] S202:根据商品边信息构建商品知识图谱；

[0081] S203:利用预设实体对齐集将二分图和商品知识图谱进行集成,获得整体协同知识图。

[0082] 具体而言,在传统的基于因子分解机制 (Factorization Machines, FM) 实现商品推荐的方法中,其将商品推荐过程转化为一个有监督的学习问题,具体为假设每个信息交互都是一个独立的实例,并对边信息进行编码,但是,该种实现方式忽略了实例或项之间的关系,例如一种商品的购买者有可能浏览/购买这个商品品牌的其他商品,因此,该方法不足以从用户的集体行为中提取协作信号。在此基础上,考虑到知识图谱 (Knowledge Graph Attention Network, KG-attention) 的效用,其可以通过将item(商品) 与其属性链接来打破独立交互假设,可以进一步想到,在KG和user-item二分图的这种混合结构中,高阶关系(将两个item与一个或多个链接属性连接起来)是成功推荐的关键因素。因此,可以利用用户与商品的二分图 (user-item二分图) 和商品知识图谱集成构建整体协同知识图,其中,用户与商品的二分图基于历史交互信息构建生成,商品知识图谱基于商品边信息构建生成。

[0083] 其中,对于user-item二分图,在推荐场景中,推荐系统内存在历史user-item的交互,因此,可以以user-item二分图的形式表示这些交互数据。假设G1代表user-item二分图,可将其定义为 $\{(u, y_{ui}, i) \mid u \in U, i \in I\}$,其中,u和i分别代表user(用户)和item(商品),链接 $y_{ui}=1$ 表示用户u与商品i之间存在观察到的交互,否则 $y_{ui}=0$ 。

[0084] 其中,对于商品知识图谱,具体可基于商品边信息构建获得,商品边信息由现实世界中的实体以及实体之间的关系组成,以描述一个item之间的关系来分析一个item,例如,商品可以由商品品牌、购买人群和商品类型来描述。假设G2代表商品知识图谱,G2是由主客体三重事实组成的有向图,可将其定义为 $\{(h, r, t) \mid h, t \in \varepsilon, r \in R\}$,表示从头部实体h到尾部实体t之间存在关系r,例如,(张三,buy,可乐)描述了“张三”购买了“可乐”的事实。

[0085] 进一步,可以建立一组项目实体对应的集合(预设实体对齐集): $A = \{(i, e) \mid i \in I, e \in \varepsilon\}$,其中 (i, e) 表示项i可以与实体e对齐,用以将user-item二分图和商品知识图谱中的实体进行对齐,进而实现二者的集成,从而生成整体协同知识图。

[0086] 最后,对于整体协同知识图谱,其将用户行为和商品知识编码为一个统一的关系图。首先,可以将每个用户行为表示为三元组 $(u, \text{interact}, i)$,其中, $y_{ui}=1$ 表示user和item之间的附加关系interact,进一步,基于项目实体对齐集A,可以将user-item二分图和商品知识图谱无缝集成为整体协同知识图 $G: G = \{(h, r, t) \mid h, t \in \varepsilon', r \in R'\}$,其中, $\varepsilon' = \varepsilon \cup u, R' = R \cup \{\text{interact}\}$ 。

[0087] 由此,将user-item二分图和商品知识图谱相集成,实现了包括有历史交互信息和商品边信息的整体协同知识图的构建。

[0088] 在上述各实施例的基础上：

[0089] 本申请实施例提供了一种预设商品推荐模型的构建方法。

[0090] 首先,参照图3,图3为本申请所提供的一种商品推荐系统中的实体交互关系图,其中,r代表实体与实体之间的关系,r1表示购买,r2表示品牌,r3表示产地,r4表示上市时间。如图3所示,用户u1和商品i1之间有一个交互r1,i1的品牌是e1,传统的协同过滤(Collaborative Filtering,CF)方法会关注同样购买了i1的相似用户的历史,即u4和u5;而有监督学习(Supervised Learning,SL)方法则强调与i1具有相似属性e1的i2。显然,以上两类信息不仅是推荐信息的补充,同时也在目标用户和商品之间形成了一种高阶关系,这种高阶关系可以为实现准确的商品推荐产生较大作用。

[0091] 但是,现有的SL方法无法考虑高阶连通性,例如,根据图4中的长范围连接 $u1 \xrightarrow{r1} i1 \xrightarrow{-r2} e1 \xrightarrow{r2} i2 \xrightarrow{-r1} \{u2, u3\}$ 和 $u1 \xrightarrow{r1} i1 \xrightarrow{-r2} e1 \xrightarrow{r3} \{i3, i4\}$ 可以得出u2和u3是购买了同一个品牌的其他商品的用户,但是这种关系很容易被传统方法忽略掉。

[0092] 为解决现有SL模型的局限性,可以选择采用基于知识图谱构建预测模型进而实现商品推荐,然而,要想实现高阶关系的充分利用,所面临的一个问题在于:与目标用户具有高阶关系的节点会随着阶数的增加而急剧增加,这给会模型带来计算过载的问题。为解决该问题,可以选择采用递归嵌入向量传播的方法,该方法可以基于邻域的嵌入向量更新节点的嵌入向量,并递归地执行这种嵌入在线性时间复杂度下捕获高阶连接的运算,可以有效减少模型的计算压力。

[0093] 在此基础上,请参考图4,图4为本申请所提供的一种预设商品推荐模型的构建方法的流程示意图,该方法可以包括:

[0094] S301:提取整体协同知识图中的各三元组,并利用各三元组构建初始商品推荐模型;

[0095] S302:对整体协同知识图中的各实体进行向量转化,获得各实体对应的嵌入向量;

[0096] S303:根据三元组中各实体对应的嵌入向量对三元组进行可信性计算,获得各三元组的可信度;

[0097] S304:利用各可信度对初始商品推荐模型进行优化,获得预设商品推荐模型。

[0098] 具体而言,三元组是指图形的几何元素构成、图线间的拓扑关系和尺寸约束,在整体协同知识图中,三元组代表实体A与实体B之间存在联系C,如上述(张三,buy,可乐)表示“张三”购买了“可乐”的事实。在预设商品模型构建过程中,首先提取整体协同知识图中的各个三元组构建初始商品推荐模型,进一步,通过对初始商品推荐模型进行优化,以获取满足要求预设商品推荐模型。

[0099] 其中,模型的优化可基于三元组的可信度实现,更低的可信度表明该三元组更可能是真实存在的。进一步,在进行可信度计算时,可以先将整体协同知识图中的各个实体进行向量转化,即将实体参数化为向量表示的形式,获得对应的嵌入向量,由此,即可利用三元组中各实体对应的嵌入向量对该三元组进行可信度计算,并通过对三元组的可信度进行优化实现模型优化。

[0100] 作为一种优选实施例,上述利用预设商品推荐模型对目标协同知识图进行处理,获得目标协同知识图中各商品的推荐值,可以包括:对目标协同知识图中的各实体进行向量转化,获得各实体对应的嵌入向量;从目标协同知识图中提取目标用户实体作为头实体的第一三元组,并利用第一三元组中各实体对应的嵌入向量对第一三元组进行计算,获得目标用户实体对应的第一网络传播结果;从目标协同知识图中提取各商品实体作为头实体

的第二三元组,并利用第二三元组中各实体对应的嵌入向量对第二三元组进行计算,获得各商品实体对应的第二网络传播结果;计算第一网络传播结果与各第二网络传播结果的内积,获得各商品的推荐值。

[0101] 具体而言,目标协同知识图中各商品实体相对于目标用户实体的推荐值的计算,同样可以基于各实体对应的嵌入向量实现,首先,将目标协同知识图中的各实体参数化为嵌入向量表示的形式,进一步,利用嵌入向量计算获得目标用户实体在神经网络中的传播结果(第一网络传播结果)和各商品实体在神经网络中的传播结果(第二网络传播结果),最后,计算二者内积作为对应商品实体相对于目标用户实体的推荐值。其中,目标用户实体在神经网络中的传播结果可利用目标用户实体作为头实体的各个三元组(第一三元组)计算获得,商品实体在神经网络中的传播结果可利用商品实体作为头实体的各个三元组(第二三元组)计算获得。对于上述头实体,以上述(张三,buy,可乐)三元组为例,其中“张三”即为头实体,“可乐”为尾实体,“buy”为头实体与尾实体之间的关系。

[0102] 可以理解的是,虽然利用商品的高阶关系进行商品推荐可以有效提高推荐结果的准确性,但是,不同的高阶关系对预测结果的贡献度是不均等的,为进一步保证商品推荐的精准度,可以将权重计算引入网络传播结果的计算过程中,通过学习网络传播过程中每个邻居节点的权重实现商品推荐值的计算,从而实现网络推荐。

[0103] 因此,作为一种优选实施例,上述利用第一三元组中各实体对应的嵌入向量对第一三元组进行计算,获得目标用户实体对应的第一网络传播结果,可以包括:根据各第一三元组中尾实体对应的嵌入向量计算获得目标用户实体在各网络传播层的加权线性组合结果;将目标用户实体对应的嵌入向量与加权线性组合结果进行信息聚合,获得各网络传播层的聚合结果;对各网络传播层的聚合结果进行连接,获得第一网络传播结果。

[0104] 在对目标用户实体在神经网络中的传播结果进行计算时,可以先计算目标用户实体在每一个网络传播层的传播结果,再将所有网络传播层的传播结果进行连接,获得最终的网络传播结果。在具体实现过程中,首先根据目标用户实体对应的各三元组中的尾实体的嵌入向量进行加权计算,获得该目标用户实体在各个网络传播层的加权线性组合结果;进一步,对于每一网络传播层,可以将目标用户实体对应的嵌入向量与其在当前网络传播层的加权线性组合结果进行信息聚合,获得目标用户实体在该网络传播层的聚合结果;最后,将所有网络传播层的聚合结果进行连接,即可获得目标用户实体在神经网络中的传播结果,即上述第一网络传播结果。

[0105] 作为一种优选实施例,上述根据各第一三元组中尾实体对应的嵌入向量计算获得目标用户实体在各网络传播层的加权线性组合结果,可以包括:利用神经网络注意力机制对各第一三元组中尾实体对应的嵌入向量进行加权平均计算,获得目标用户实体在各网络传播层的加权线性组合结果。

[0106] 本优选实施例提供了一种权重计算方法,即基于神经网络注意力机制实现。具体而言,注意力机制的原理在于将注意力集中在当前重要的信息上,而忽略其他不重要的因素,即只关注部分重要数据信息。由此,利用神经网络注意力机制来学习网络传播过程中每个邻居节点的权重,通过这样级联传播的注意力权重揭示高阶连接的重要性,可以实现更为准确的商品推荐。

[0107] 此外,商品实体在神经网络中的传播结果的计算同样可以基于上述方法实现。因

此,上述从目标协同知识图中提取各商品实体作为头实体的第二三元组,并利用第二三元组中各实体对应的嵌入向量对第二三元组进行计算,获得各商品实体对应的第二网络传播结果,可以包括:根据各第二三元组中尾实体对应的嵌入向量计算获得商品实体在各网络传播层的加权线性组合结果;将商品实体对应的嵌入向量与加权线性组合结果进行信息聚合,获得各网络传播层的聚合结果;对各网络传播层的聚合结果进行连接,获得第二网络传播结果。

[0108] 由此,基于递归嵌入向量传播方法和神经网络注意力机制实现了预设商品推荐模型的构建,该模型可以以端到端的方式充分利用系统内的高阶关系,从而实现更为准确的商品推荐。

[0109] 结合上述各实施例,本申请实施例提供了又一种商品推荐方法。

[0110] 本申请实施例所提供的商品推荐方法,基于协同知识图构建商品推荐模型,该模型可以以端到端的方式利用系统内的高阶关系,模型输入为目标用户对应的协同知识图G,输出为目标用户购买各商品的概率,由此即可基于概率值实现商品推荐。

[0111] 首先,请参考图5,图5为本申请所提供的一种预设商品推荐模型的框架图,该预设商品推荐模型的整体框架由三个主要组建组成:

[0112] (1) 嵌入层:通过保留CKG的结构将每个节点参数化为向量;

[0113] (2) 注意力嵌入传播层:递归地从节点的邻居传播嵌入以更新其表示,并使用知识感知注意力机制在传播过程中学习每个邻居的权重;

[0114] (3) 预测层:从所有传播层聚合user和item的表示,并输出预测的得分。

[0115] 其中,知识图嵌入是一种在保持图结构不变的情况下,将实体和关系参数化为向量表示的有效方法,可以采用TransR模型实现。具体来说,在目标用户对应的协同知识图G中,对于一个三元组 (h, r, t) ,其可以通过优化平移原理 $e_h^r + e_r \approx e_t^r$ 来学习向量化每个实体和关系,其中, $e_h, e_t \in \mathbb{R}^d$ 和 $e_r \in \mathbb{R}^k$ 分别是 h, t 和 r 的嵌入向量表示, e_h^r 和 e_t^r 分别是关系 r 空间中的 e_h 和 e_t 的投影表示,此时,对于该三元组 (h, r, t) ,其可信性得分计算公式为:

$$[0116] \quad g(h, r, t) = \|W_r e_h + e_r - W_r e_t\|_2^2$$

[0117] 其中, $W_r \in \mathbb{R}^{k \times d}$ 是关系 r 的变换矩阵,表示将实体从 d 维实体空间投影到 k 维关系空间。可以理解的是,更低分数 $g(h, r, t)$ 表明三元组更可能是真的,因此,可以通过优化可信性得分实现预设商品推荐模型的优化。

[0118] 进一步,在图卷积网络的基础上,沿着高阶连通性递归地传播嵌入向量,同时,通过利用图注意力网络的思想生成级联传播的注意力权重,以揭示上述连通性的重要性。

[0119] 在计算过程中,可以先对单层传播网络进行计算,然后推广到多层传播网络。其中,一个单层传播网络由三部分组成,分别为信息传播、知识感知注意力和信息聚合。

[0120] 1、信息传播:一个实体可以参与多个三元组,充当连接两个三元组和传播信息的桥梁,以 $e_1 \xrightarrow{r_2} i_2 \xrightarrow{-r_1} u_2$ 和 $e_2 \xrightarrow{r_3} i_2 \xrightarrow{-r_1} u_2$ 为例:项 i_2 将属性 e_1 和 e_2 作为输入,以丰富其自身特性,然后贡献用户 u_2 的偏好,这可以通过从 e_1 到 u_2 传播信息来模拟,因此,可以基于这种直觉在一个实体和它的邻居之间进行信息传播。对于一个实体 h ,可以使用 $N_h = \{(h, r, t) \mid (h, r, t) \in G\}$ 来表示其三元组,其中, h 是头实体,对于一个头实体 h ,可以先将所有头实体为 h 的关系拿

出来,然后把所有这些关系中的尾实体t的嵌入向量进行加权平均计算,获得一个h的表达,其中,为了刻画实体h的一阶连通结构,可以计算h的加权线性组合:

$$[0121] \quad e_{N_h} = \sum_{(h,r,t) \in N_h} \pi(h,r,t) e_t$$

[0122] 其中, $\pi(h,r,t)$ 控制边 (h,r,t) 上每次传播的衰减因子,指示从t到h传播的信息与关系r的条件。

[0123] 2、知识感知注意力:可以通过相关的注意力机制实现 $\pi(h,r,t)$ 计算,计算公式为: $\pi(h,r,t) = (W_r e_r) \tanh(W_r e_h + e_r)$,其中, $\tanh$ 为非线性激活函数,该计算方式使得注意力得分依赖于关系r空间中的两个 e_h 和 e_t 之间的距离,例如,为更接近的实体传播更多的信息。其中,为简单起见,可以只在这些表示上使用内积。进一步,通过采用softmax函数对与h相连的所有三元组的系数进行归一化:

$$[0124] \quad \pi(h,r,t) = \frac{\exp(\pi(h,r,t))}{\sum_{(h,r',t') \in N_h} \exp(\pi(h,r',t'))}$$

[0125] 由此,最后的注意力得分能够提示哪些邻居节点应该给予更多的注意来捕获协作信号。并且,当执行前馈传播时,注意力会建议关注部分数据,这可以视为推荐背后的解释。

[0126] 3、信息聚合:将实体 e_h 表示及其 e_{N_h} 表示聚合为实体h的新表示,即:

$e_h^{(1)} = f(e_h, e_{N_h})$ 。其中,f函数可以利用GCN Aggregator (GCN聚合器 (Graph Convolutional Network, 图卷积网络)) 计算获得。GCN Aggregator总结了两种表示并应用非线性变换: $f_{GCN} = \text{LeakyReLU}(W(e_h + e_{N_h}))$,其中,LeakyReLU为激活函数, $W \in \mathbb{R}^{d' \times d}$ 是可训练权重矩阵,以提取有用的传播信息。

[0127] 进一步,基于以上单层传播网络的计算方法进入高阶传播,可以通过堆叠更多的传播层来探索高阶连接性信息,收集从更高跳邻居传播的信息,即使用新的 e_h 更新新的 e_{N_h} ,如此往复循环,即可实现多层网络传播。具体来说,是将从第0层到第L层所有的 e_h 和 e_{N_h} 连接起来做成一个新的表示向量: $e_h^* = e_h^0 \parallel \dots \parallel e_h^L$ 。由于是商品推荐,因此,需要计算每个用户的表示向量: $e_u^* = e_u^0 \parallel \dots \parallel e_u^L$,以及不同商品的表示向量: $e_i^* = e_i^0 \parallel \dots \parallel e_i^L$,其中, $\parallel$ 表示串联操作,如此,不仅可以通过执行嵌入传播操作来丰富初始嵌入,还可以通过调整L来控制传播强度。

[0128] 最后,对用户和商品的表示做内积,得到用户要购买这个商品的分数:

$$y(u,i) = e_u^{*T} \bullet e_i^*, \text{从而根据该分数值达到推荐的目的。}$$

[0129] 由此可见,本申请实施例所提供的商品推荐方法,提出了一种基于知识图谱和注意力机制的推荐算法,对CKG中高阶路径上的节点之间的语义关系进行了研究,并提出了一种基于注意力机制的高阶路径节点表示传播算法,利用网络中的邻接节点递归更新中心节点的向量表示,最后通过计算用户和商品的向量内积作为商品推荐的分数实现商品推荐,极大地提高了商品推荐的精确度和成功率,从而可以更为有效地满足用户需求,提高用户体验。

[0130] 为解决上述技术问题,本申请还提供了一种商品推荐装置,请参考图6,图6为本申

请所提供的一种商品推荐装置的结构示意图,该商品推荐装置可包括:

[0131] 目标用户确定模块1,用于确定目标用户;

[0132] 目标协同知识图获取模块2,用于从整体协同知识图中获取目标用户对应的目标协同知识图;其中,整体协同知识图根据历史交互信息和商品边信息构建获得;

[0133] 商品推荐值计算模块3,用于利用预设商品推荐模型对目标协同知识图进行处理,获得目标协同知识图中各商品的推荐值;其中,预设商品推荐模型根据整体协同知识图构建获得;

[0134] 商品推荐模块4,用于将推荐值超出预设阈值的商品推荐给目标用户。

[0135] 可见,本申请实施例所提供的商品推荐装置,利用各用户与各商品之间的历史交互信息以及各商品的边信息构建协同知识图,并利用预设商品推荐模型对目标用户对应的目标协同知识图进行分析处理,从而在目标协同知识图中确定推荐值超出预设阈值的商品向目标用户进行商品推荐,由此可见,通过将历史交互信息与商品边信息相结合构建用户与商品之间的联系,同时利用商品推荐模型实现动态的商品推荐,极大地提高了商品推荐的精确度和成功率,从而可以更为有效地满足用户需求,提高用户体验。

[0136] 作为一种优选实施例,该商品推荐装置还可包括整体协同知识图构建模块,用于根据历史交互信息构建用户与商品的二分图;根据商品边信息构建商品知识图谱;利用预设实体对齐集将二分图和商品知识图谱进行集成,获得整体协同知识图。

[0137] 作为一种优选实施例,该商品推荐装置还可包括预设商品推荐模型构建模块,用于提取整体协同知识图中的各三元组,并利用各三元组构建初始商品推荐模型;对整体协同知识图中的各实体进行向量转化,获得各实体对应的嵌入向量;根据三元组中各实体对应的嵌入向量对三元组进行可信性计算,获得各三元组的可信度;利用各可信度对初始商品推荐模型进行优化,获得预设商品推荐模型。

[0138] 作为一种优选实施例,上述商品推荐值计算模块3可包括:

[0139] 向量转化单元,用于对目标协同知识图中的各实体进行向量转化,获得各实体对应的嵌入向量;

[0140] 第一网络传播子模块,用于从目标协同知识图中提取目标用户实体作为头实体的第一三元组,并利用第一三元组中各实体对应的嵌入向量对第一三元组进行计算,获得目标用户实体对应的第一网络传播结果;

[0141] 第二网络传播子模块,用于从目标协同知识图中提取各商品实体作为头实体的第二三元组,并利用第二三元组中各实体对应的嵌入向量对第二三元组进行计算,获得各商品实体对应的第二网络传播结果;

[0142] 推荐值计算的子模块,用于计算第一网络传播结果与各第二网络传播结果的内积,获得各商品的推荐值。

[0143] 作为一种优选实施例,上述第一网络传播子模块可包括:

[0144] 加权计算单元,用于根据各第一三元组中尾实体对应的嵌入向量计算获得目标用户实体在各网络传播层的加权线性组合结果;

[0145] 信息聚合单元,用于将目标用户实体对应的嵌入向量与加权线性组合结果进行信息聚合,获得各网络传播层的聚合结果;

[0146] 网络连接单元,用于对各网络传播层的聚合结果进行连接,获得第一网络传播结

果。

[0147] 作为一种优选实施例,上述加权计算单元可具体用于利用神经网络注意力机制对各第一三元组中尾实体对应的嵌入向量进行加权平均计算,获得目标用户实体在各网络传播层的加权线性组合结果。

[0148] 作为一种优选实施例,该商品推荐装置还可包括模型更新模块,用于更新历史交互信息和/或商品边信息;利用更新后的历史交互信息和/或商品边信息对整体协同知识图进行更新,获得更新后的整体协同知识图;利用更新后的整体协同知识图对预设商品推荐模型进行更新。

[0149] 对于本申请提供的装置的介绍请参照上述方法实施例,本申请在此不做赘述。

[0150] 为解决上述技术问题,本申请还提供了一种商品推荐系统,请参考图7,图7为本申请所提供的一种商品推荐系统的结构示意图,该商品推荐系统可包括:

[0151] 存储器10,用于存储计算机程序;

[0152] 处理器20,用于执行计算机程序时可实现如上述任意一种商品推荐方法的步骤。

[0153] 具体的,请参考图8,图8为本申请所提供的一种商品推荐系统的具体结构示意图,该商品推荐系统100可因配置或性能不同而产生比较大的差异,可以包括处理器(central processing units,CPU)20(例如,一个或一个以上处理器)和存储器10,存储器10存储有一个或一个以上的计算机应用程序11或数据12。其中,存储器10可以是短暂存储或持久存储。存储在存储器10的计算机程序11可以包括一个或一个以上模块(图示未标出),每个模块可以包括对商品推荐系统100中的一系列指令操作。更进一步地,处理器20可以设置为与存储器10通信,在商品推荐系统100上执行存储器10中的一系列指令操作。

[0154] 商品推荐系统100还可以包括一个或一个以上电源30,一个或一个以上有线或无线网络接口40,一个或一个以上输入输出接口50,和/或,一个或一个以上操作系统13。

[0155] 上文所描述的商品推荐方法中的步骤可以由上述商品推荐系统的结构实现。

[0156] 为解决上述问题,本申请还提供了一种计算机可读存储介质,该计算机可读存储介质上存储有计算机程序,计算机程序被处理器执行时可实现如上述任意一种商品推荐方法的步骤。

[0157] 该计算机可读存储介质可以包括:U盘、移动硬盘、只读存储器(Read-Only Memory,ROM)、随机存取存储器(Random Access Memory,RAM)、磁碟或者光盘等各种可以存储程序代码的介质。

[0158] 对于本申请提供的计算机可读存储介质的介绍请参照上述方法实施例,本申请在此不做赘述。

[0159] 说明书中各个实施例采用递进的方式描述,每个实施例重点说明的都是与其他实施例的不同之处,各个实施例之间相同相似部分互相参见即可。对于实施例公开的装置而言,由于其与实施例公开的方法相对应,所以描述的比较简单,相关之处参见方法部分说明即可。

[0160] 专业人员还可以进一步意识到,结合本文中所公开的实施例描述的各示例的单元及算法步骤,能够以电子硬件、计算机软件或者二者的结合来实现,为了清楚地说明硬件和软件的可互换性,在上述说明中已经按照功能一般性地描述了各示例的组成及步骤。这些功能究竟以硬件还是软件方式来执行,取决于技术方案的特定应用和设计约束条件。专业

技术人员可以对每个特定的应用来使用不同方法来实现所描述的功能,但是这种实现不应认为超出本申请的范围。

[0161] 结合本文中所公开的实施例描述的方法或算法的步骤可以直接用硬件、处理器执行的软件模块,或者二者的结合来实施。软件模块可以置于随机存储器 (RAM)、内存、只读存储器 (ROM)、电可编程ROM、电可擦除可编程ROM、寄存器、硬盘、可移动磁盘、CD-ROM或技术领域中所周知的任意其它形式的存储介质中。

[0162] 以上对本申请所提供的技术方案进行了详细介绍。本文中应用了具体个例对本申请的原理及实施方式进行了阐述,以上实施例的说明只是用于帮助理解本申请的方法及其核心思想。应当指出,对于本技术领域的普通技术人员来说,在不脱离本申请原理的前提下,还可以对本申请进行若干改进和修饰,这些改进和修饰也落入本申请的保护范围内。




图1




图2




图3




图4




图5




图6




图7




图8