



(12)发明专利申请

(10)申请公布号 CN 109446430 A

(43)申请公布日 2019.03.08

(21)申请号 201811446282.2

(22)申请日 2018.11.29

(71)申请人 西安电子科技大学

地址 710000 陕西省西安市太白南路2号西安电子科技大学

(72)发明人 宋彬 吕军梅 郭洁 罗文雯

(74)专利代理机构 北京华仲龙腾专利代理事务所(普通合伙) 11548

代理人 李静

(51)Int.Cl.

G06F 16/9535(2019.01)

G06F 17/16(2006.01)

G06K 9/62(2006.01)

G06Q 30/06(2012.01)

权利要求书3页 说明书12页 附图9页

(54)发明名称

产品推荐的方法、装置、计算机设备及可读存储介质

(57)摘要

本发明适用于计算机领域,提供了一种产品推荐方法。所述方法包括:提取待推荐产品及与待推荐用户有历史交互的产品的特征信息;获取与待推荐用户有历史交互的产品的特征信息;获取与待推荐用户有历史交互关系的用户,并将用户与产品组合生成样本集;利用深度学习对预测函数集成模型进行训练,以获取待推荐用户的隐因子向量、待推荐产品的隐因子向量并确定预测函数集成模型;根据待推荐用户的隐因子向量、待推荐产品的隐因子向量以及预测函数集成模型计算用户对各产品的预测交互矩阵;根据所述预测交互矩阵对各产品进行排序,将排序靠前的产品推荐给待推荐用户。本发明实施例提供的产品推荐方法,利用了产品的多模态数据如图像、文本等,提高了对特征信息的利用率,从而提高了产品推荐的效果。

CN 109446430 A



1. 一种产品推荐的方法,其特征在于,所述方法包括以下步骤:

根据待推荐的产品集合以及待推荐用户历史交互的产品集合中各产品的多模态数据提取所述各产品的特征信息,所述各产品的多模态数据包括各产品的可视化图像信息以及各产品的文本信息,所述各产品的特征信息包括各产品的图像信息隐因子向量以及文本信息隐因子向量;

获取与所述待推荐的各产品以及所述待推荐用户历史交互的各产品有过交互关系的样本用户,并与所述待推荐的各产品以及所述待推荐用户历史交互的各产品组合生成样品集合,所述样品集合还包括样本用户与所述推荐的各产品以及待推荐用户历史交互的各产品之间的交互数据;

根据所述样品集合利用深度学习对含有可变参数的预测函数集成模型进行训练,以确定待推荐户的隐因子向量、待推荐产品的隐因子向量以及所述预测函数集成模型中的可变参数,所述预测函数集成模型包括基于产品隐因子向量的传统矩阵分解模型、基于可视化图像信息的矩阵分解模型以及基于文本信息的矩阵分解模型;

根据所述待推荐用户的隐因子向量、待推荐的隐因子向量以及利用深度学习训练出的含有确定参数的预测函数集成模型计算待推荐用户对各待推荐的产品的预测交互矩阵,所述预测交互矩阵中各数值的大小表示所述待推荐用户对所述各待推荐的产品的偏好概率;

根据所述预测交互矩阵对所述待推荐的产品集合中各产品进行排序,并将排序靠前的产品推荐给所述待推荐用户。

2. 根据权利要求1所述的方法,其特征在于,所述根据待推荐的产品集合以及待推荐用户历史交互的产品集合中各产品的模态数据提取所述各产品的特征信息的步骤,具体包括:

利用深度残差网络处理所述待推荐的产品集合以及待推荐用户历史交互的产品集合中各产品的可视化图像信息,并提取各产品的图像信息隐因子向量;

利用文本向量建模模型处理所述待推荐的产品集合以及待推荐用户历史交互的产品集合中各产品的文本信息,并提取各产品的文本信息隐因子向量。

3. 根据权利要求2所述的方法,其特征在于,所述根据所述样品集合利用深度学习对含有可变参数的预测函数集成模型进行训练,以确定待推荐户的隐因子向量、待推荐产品的隐因子向量以及所述预测函数集成模型中的可变参数的步骤,具体包括:

按照预设的规则从所述样品集合中获取训练集合,所述训练集合包括多个用户-产品对;

获取训练集合中用户的隐因子向量以及产品的隐因子向量,并根据基于产品的隐因子向量的传统矩阵分解模型,输出第一预测交互矩阵;

计算所述第一预测交互矩阵与所述训练集合中用户与产品的交互矩阵的第一差异值;

获取训练集合中用户的隐因子向量以及产品的图像信息隐因子向量,并根据基于可视化图像信息的矩阵分解模型,输出第二预测交互矩阵;

计算所述第二预测交互矩阵与所述训练集合中用户与产品的交互矩阵的第二差异值;

获取训练集合中用户的隐因子向量以及产品的文本信息隐因子向量,并根据基于文本信息的矩阵分解模型,输出第三预测交互矩阵;

计算所述第三预测交互矩阵与所述训练集合中用户与产品的交互矩阵的第三差异值;

计算所述第一差异值、第二差异值以及第三差异值的总和；

判断所述差异值的总和是否满足预设的要求；

当判断所述差异值不满足预设的要求时，根据所述第一差异值、第二差异值以及第三差异值的大小，利用误差反向传播算法，梯度逐级回传调整所述用户的隐因子向量、产品的隐因子向量以及所述预测函数集成模型中的可变参数，并返回至所述获取训练集中用户的隐因子向量以及产品的隐因子向量，并根据基于产品的隐因子向量的传统矩阵分解模型，输出第一预测交互矩阵的步骤；

当判断所述差异值满足预设的要求时，确定待推荐户的隐因子向量、待推荐产品的隐因子向量以及所述预测函数集成模型中的可变参数。

4. 根据权利要求3所述的方法，其特征在于，所述按照预设的规则从所述样本集合中获取训练集合的步骤，具体包括：

获取所述样本集合中的全部正样本，所述正样本为所述样本集合中存在交互关系的用户-产品对；

获取所述样本集合中的多个负样本，所述负样本为所述样本集合中不存在交互关系的用户-产品对；

将所述正样本与所述负样本组合生成训练集合。

5. 根据权利要求1所述的方法，其特征在于，在所述根据所述待推荐用户的隐因子向量、待推荐的隐因子向量以及利用深度学习训练出的含有确定参数的预测函数集成模型计算待推荐用户对各待推荐的产品的预测交互矩阵的步骤前，还包括：

根据所述样本集合以及利用深度学习训练出的含有确定参数的预测函数集成模型衡量所述含有确定参数的预测函数集成模型的推荐效果。

6. 根据权利要求5所述的方法，其特征在于，所述根据所述样本集合以及利用深度学习训练出的含有确定参数的预测函数集成模型衡量所述含有确定参数的预测函数集成模型的推荐效果的步骤，具体包括：

按照预设的规则对样品集中每个用户生成一个测试集合，所述用户的测试集合包括一个存在交互的关系的所述用户-产品对，以及多个不存在交互的关系的所述用户-产品对；

获取第一用户测试集合中所述第一用户的隐因子向量以及产品的隐因子向量；

根据所述第一用户的隐因子向量、第一用户测试集合中各产品的隐因子向量以及利用深度学习训练出的含有确定参数的预测函数集成模型计算所述第一用户对第一用户测试集合中各产品的测试交互矩阵，所述测试交互矩阵中数值的大小表示所述第一用户对相应产品的偏好的概率；

根据所述测试交互矩阵对所述第一用户测试集合中各产品进行排序；

统计所述第一测试集合中正样品中相应的产品在所述排序中的位置；

根据所述统计的结果计算点击率和归一化折损累计增益，所述点击率和归一化折损累计增益可用于标识所述含有确定参数的预测函数集成模型的推荐效果。

7. 一种产品推荐的装置，其特征在于，所述装置包括：

产品数据采集单元，用于根据待推荐的产品集合以及待推荐用户历史交互的产品集合中各产品的多模态数据提取所述各产品的特征信息，所述各产品的多模态数据包括各产品的可视化图像信息以及各产品的文本信息，所述各产品的特征信息包括各产品的图像信息

隐因子向量以及文本信息隐因子向量；

样本集合生成单元,用于获取与所述待推荐的各产品以及所述待推荐用户历史交互的各产品有过交互关系的样本用户,并与所述待推荐的各产品以及所述待推荐用户历史交互的各产品组合生成样品集合,所述样品集合还包括样本用户与所述推荐的各产品以及待推荐用户历史交互的各产品之间的交互数据;

预测函数集成模型训练单元,用于根据所述样本集合利用深度学习对含有可变参数的预测函数集成模型进行训练,以确定待推荐户的隐因子向量、待推荐产品的隐因子向量以及所述预测函数集成模型中的可变参数,所述预测函数集成模型包括基于产品隐因子向量的传统矩阵分解模型、基于可视化图像信息的矩阵分解模型以及基于文本信息的矩阵分解模型;

预测交互矩阵计算单元,用于根据所述待推荐用户的隐因子向量、待推荐的隐因子向量以及利用深度学习训练出的含有确定参数的预测函数集成模型计算待推荐用户对各待推荐的产品的预测交互矩阵,所述预测交互矩阵中各数值的大小表示所述待推荐用户对所述各待推荐的产品的偏好概率;以及

推荐单元,用于根据所述预测交互矩阵对所述待推荐的产品集合中各产品进行排序,并将排序靠前的产品推荐给所述待推荐用户。

8. 一种计算机设备,包括存储器和处理器,其特征在于,所述存储器中存储有计算机程序,所述计算机程序被所述处理器执行时,使得所述处理器执行权利要求1至6中任一项权利要求所述产品推荐方法的步骤。

9. 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上存储有计算机程序,所述计算机程序被处理器执行时,使得所述处理器执行权利要求1至6中任一项权利要求所述产品推荐方法的步骤。

产品推荐的方法、装置、计算机设备及可读存储介质

技术领域

[0001] 本发明涉及计算机领域,特别是涉及一种产品推荐的方法、装置、计算机设备及可读存储介质。

背景技术

[0002] 在线内容和服务的爆炸性增长使得用户在面对大量选择时无法高效获得有用的信息,例如新闻、电影、音乐、服装、餐馆和书籍。为了缓解信息过载,搜索引擎与推荐系统应运而生。个性化推荐系统是建立在大数据基础上的一种智能算法和决策,为线上用户提供完全个性化的决策支持和信息服务。

[0003] 然而现有的推荐系统都是基于产品的传统分类以及传统矩阵分解模型对用户进行推荐,例如推荐电影时,仅仅根据电影的传统标签将产品分为恐怖、动画、剧情、记录、动作等等并依此对用户进行推荐,而对其他隐含的特征信息的利用率较低,从而使得最终推荐的效果不理想。

[0004] 可见现有技术中的推荐算法存在着特征信息利用率低,推荐效果不理想的技术问题。

发明内容

[0005] 本发明实施例提供一种产品推荐的方法、装置、计算机设备及可读存储介质方法,以解决现有技术中的推荐算法存在的特征信息利用率低,推荐效果不理想的技术问题。

[0006] 本发明实施例提供一种产品推荐的方法,所述方法包括以下步骤:

[0007] 根据待推荐的产品集合以及待推荐用户历史交互的产品集合中各产品的多模态数据提取所述各产品的特征信息,所述各产品的多模态数据包括各产品的可视化图像信息以及各产品的文本信息,所述各产品的特征信息包括各产品的图像信息隐因子向量以及文本信息隐因子向量;

[0008] 获取与所述待推荐的各产品以及所述待推荐用户历史交互的各产品有过交互关系的样本用户,并与所述待推荐的各产品以及所述待推荐用户历史交互的各产品组合生成样品集合,所述样品集合还包括样本用户与所述推荐的各产品以及待推荐用户历史交互的各产品之间的交互数据;

[0009] 根据所述样本集合利用深度学习对含有可变参数的预测函数集成模型进行训练,以确定待推荐用户的隐因子向量、待推荐产品的隐因子向量以及所述预测函数集成模型中的可变参数,所述预测函数集成模型包括基于产品隐因子向量的传统矩阵分解模型、基于可视化图像信息的矩阵分解模型以及基于文本信息的矩阵分解模型;

[0010] 根据所述待推荐用户的隐因子向量、待推荐的隐因子向量以及利用深度学习训练出的含有确定参数的预测函数集成模型计算待推荐用户对各待推荐的产品预测交互矩阵,所述预测交互矩阵中各数值的大小表示所述待推荐用户对所述各待推荐的产品的

偏好概率；

[0011] 根据所述预测交互矩阵对所述待推荐的产品集合中各产品进行排序,并将 排序靠前的产品推荐给所述待推荐用户。

[0012] 本发明实施例还提供一种产品推荐的装置,所述装置包括:

[0013] 产品数据采集单元,用于根据待推荐的产品集合以及待推荐用户历史交互 的产品集合中各产品的多模态数据提取所述各产品的特征信息,所述各产品的 多模态数据包括各产品的可视化图像信息以及各产品的文本信息,所述各产品 的特征信息包括各产品的图像信息隐因子向量以及文本信息隐因子向量;

[0014] 样本集合生成单元,用于获取与所述待推荐的各产品以及所述待推荐用户 历史交互的各产品有过交互关系的样本用户,并与所述待推荐的各产品以及所 述待推荐用户历史交互的各产品组合生成样品集合,所述样品集合还包括样本 用户与所述推荐的各产品以及待推荐用户历史交互的各产品之间的交互数据;

[0015] 预测函数集成模型训练单元,用于根据所述样本集合利用深度学习对含有 可变参数的预测函数集成模型进行训练,以确定待推荐户的隐因子向量、待推 荐产品的隐因子向量以及所述预测函数集成模型中的可变参数,所述预测函数 集成模型包括基于产品隐因子向量的传统矩阵分解模型、基于可视化图像信息 的矩阵分解模型以及基于文本信息的矩阵分解模型;

[0016] 预测交互矩阵计算单元,用于根据所述待推荐用户的隐因子向量、待推荐 的隐因子向量以及利用深度学习训练出的含有确定参数的预测函数集成模型计 算待推荐用户对各待推荐的产品的预测交互矩阵,所述预测交互矩阵中各数值 的大小表示所述待推荐用户对所述各待推荐的产品的偏好概率;以及

[0017] 推荐单元,用于根据所述预测交互矩阵对所述待推荐的产品集合中各产品 进行排序,并将排序靠前的产品推荐给所述待推荐用户。

[0018] 本发明实施例还提供一种计算机装置,所述计算机装置包括处理器,所述 处理器用于执行存储器中存储的计算机程序时实现如上述所述产品推荐方法的 步骤。

[0019] 本发明实施例还提供一种计算机可读存储介质,所述计算机可读存储介质 上存储有计算机程序,所述计算机程序被处理器执行时,使得所述处理器执行 上述所述产品推荐方法的步骤。

[0020] 本发明实施例公开的的产品推荐方法,通过将待推荐产品、与待推荐的用 户有过历史交互的产品组合构成产品集,并根据产品集中各产品的多模态数据 提取各产品的特殊特征信息,将与上述产品集有过历史交互的用户组合构成用 户集,将产品集与用户集组合构成样本集合,根据样本集合中各用户与产品之 间是否发生过交互的数据,利用深度学习训练出确定的预测函数集成模型,以 及各用户的隐因子向量,在获取待推荐用户的隐因子向量以及确定的预测函数 集成模型后,根据待推荐用户的隐因子向量以及待推荐产品的特征信息,利用 预测函数集成模型计算出所述待推荐用户对各待推荐产品的偏好概率, 从而将 偏好概率较高的产品推荐给相应的用户。本发明实施例公开的产品推荐的方法, 相比于现有技术,获取并处理产品的可视化信息,包括海报、宣传画、简介、说明书等,提取了相应的可视化图像特征信息和文本特征信息,充分利用产品 的特征信息,有效地提高了最终推荐的效果。

附图说明

- [0021] 图1为本发明实施例提供的一种产品推荐方法的步骤流程图；
- [0022] 图2为本发明实施例中提取产品特征信息的步骤流程图；
- [0023] 图3为本发明实施例中采用的深度残差网络的结构示意图；
- [0024] 图4为本发明实施例中建立的样本集合形式的示意图；
- [0025] 图5为本发明实施例中训练预测函数集成模型的具体步骤流程图；
- [0026] 图6为本发明实施例中提供的预测模型的结构示意图；
- [0027] 图7为本发明另一个实施例中产品推荐方法的步骤流程图；
- [0028] 图8为本发明实施例提供的衡量预测函数集成模型的推荐效果的步骤流程图；
- [0029] 图9为本发明实施例提供的一种产品推荐装置的结构示意图。

具体实施方式

[0030] 为了使本发明的目的、技术方案及优点更加清楚明白,以下结合附图及实施例,对本发明进行进一步详细说明。应当理解,此处所描述的具体实施例仅用以解释本发明,并不用于限定本发明。

[0031] 本发明实施例为提供一种推荐效果好的产品推荐方法,通过构建了样本集合,所述样本集合包括待推荐产品以及待推荐用户,通过样本集合以及深度算法训练出预测函数集成模型,以及待推荐产品与待推荐用户的特征信息,并再次利用训练出的预测函数集成模型计算待推荐用户对各待推荐产品的偏好概率,将偏好概率较大的待推荐产品推荐给待推荐用户,从而提高了推荐的效果。

[0032] 图1为本发明实施例提供的一种产品推荐方法的步骤流程图,详述如下。

[0033] 步骤S101,根据待推荐的产品集合以及待推荐用户历史交互的产品集合中各产品的多模态数据提取所述各产品的特征信息。

[0034] 在本发明实施例中,所述各产品的多模态数据包括各产品的可视化图像信息以及各产品的文本信息,进一步的,所述产品的可视化图像信息包括如产品的海报、宣传画等可以直观获取的图像,所述产品的文本信息包括如产品的说明书、简介、使用方法等可以直观获取的文本。

[0035] 在本发明实施例中,与现有技术不同之处在于所述各产品的特征信息除了常规的传统分类信息外,还包括从可视化图像信息中提取的图像信息隐因子向量以及从文本信息中提取的文本信息隐因子向量。

[0036] 步骤S102,获取与所述待推荐的各产品以及所述待推荐用户历史交互的各产品有过交互关系的样本用户,并与所述待推荐的各产品以及所述待推荐用户历史交互的各产品组合生成样品集合。

[0037] 在本发明实施例中,待推荐用户也存在于所述样品集合中。

[0038] 在本发明实施例中,为确认待推荐用户的兴趣特征信息,需通过所述待推荐用户历史交互的产品的特征信息来判断。

[0039] 在本发明实施例中,所述样本集合呈矩阵形式,所述样本集合还包括样本用户与所述推荐的各产品以及待推荐用户历史交互的各产品之间的交互数据。

[0040] 在本发明实施例中,所述样本集合的形式请参阅图4。

[0041] 步骤S103,根据所述样本集合利用深度学习对含有可变参数的预测函数集成模型进行训练,以确定待推荐户的隐因子向量、待推荐产品的隐因子向量以及所述预测函数集成模型中的可变参数。

[0042] 在本发明实施例中,所述预测函数集成模型包括基于产品隐因子向量的传统矩阵分解模型、基于可视化图像信息的矩阵分解模型以及基于文本信息的矩阵分解模型。

[0043] 在本发明实施例中,所述基于产品隐因子向量的传统矩阵分解模型的计算公式如下:

$$[0044] \quad R_1 = \sigma(U^T V)$$

[0045] 在本发明实施例中, R_1 表示基于产品的隐因子向量的传统矩阵分解模型的预测交互矩阵, U 表示用户的隐因子矩阵,该矩阵的行数为用户数,列数为隐因子维度, V 表示产品的隐因子矩阵,该矩阵的行数为产品数,列数为隐因子维度, σ 表示Sigmoid函数(S型生长曲线),具体函数表达式为:

$$[0046] \quad \sigma(x) = \frac{1}{1+e^{-x}}$$

[0047] 在本发明实施例中,所述 U 、 V 为可变参数,其中 U 、 V 两个矩阵中各数据采用高斯分布初始化,均值为0,标准差为0.1。

[0048] 在本发明实施例中,所述 $U^T V$ 的计算结果为行数为产品、列数为用户的矩阵形式。

[0049] 在本发明实施例中,由于Sigmoid函数的输出值的范围在0~1之间,因此,可用来表示根据传统矩阵分解模型预测出的用户与产品交互的概率,输出值越大,越接近1表示用户与产品交互的可能性越大。

[0050] 在本发明实施例中,所述基于可视化图像信息的矩阵分解模型的计算公式如下:

$$[0051] \quad R_2 = \sigma(R_1 + U^T f_2(I))$$

[0052] 在本发明实施例中, R_2 表示基于可视化图像信息的矩阵分解模型的预测交互矩阵,所述 R_2 建立在所述基于产品的隐因子向量的传统矩阵分解模型的预测交互矩阵 R_1 之上。

[0053] 在本发明实施例中,所述 U 代表用户隐因子矩阵,与前述传统矩阵分解模型中的 U 共享, I 表示各产品的图像信息隐因子向量,为单层感知机模型代表图像信息特征学习函数,具体表达式为:

$$[0054] \quad f_2(I) = \sigma(W_2 \cdot I + b_2)$$

[0055] 其中 W_2 、 b_2 为可变参数, W_2 为权重参数,用于表示各图像信息隐因子向量的权重, b_2 为偏置项,进一步的, W_2 采用高斯分布初始化,均值为0,标准差为0.1, b_2 初始化为0。

[0056] 在本发明实施例中, σ 函数与前述传统矩阵分解模型中的 σ 函数的表达式相同,意义相近,用来表示根据基于可视化图像信息的矩阵分解模型预测出的用户与产品交互的概率。

[0057] 在本发明实施例中,所述基于文本信息的矩阵分解模型的计算公式如下:

$$[0058] \quad R_3 = \sigma(R_2 + U^T f_3(T))$$

[0059] 在本发明实施例中, R_3 表示基于文本信息的矩阵分解模型的预测交互矩阵,所述 R_3 建立在所述基于可视化图像信息的矩阵分解模型的预测交互矩阵 R_2 之上。

[0060] 在本发明实施例中,所述 U 代表用户隐因子矩阵,与前述传统矩阵分解模型中的 U

共享, T 表示各产品的文本信息隐因子向量,为单层感知机模型代表文本信息特征学习函数,具体表达式为:

$$[0061] \quad f_3(T) = \sigma(W_3 \cdot T + b_3)$$

[0062] 其中 W_3 、 b_3 为可变参数, W_3 为权重参数,用于表示各文本信息隐因子向量的权重, b_3 为偏置项,进一步的, W_3 采用高斯分布初始化,均值为0,标准差为0.1, b_3 初始化为0。

[0063] 在本发明实施实例中, σ 函数与前述传统矩阵分解模型中的 σ 函数的表达式相同,意义相近,用来表示根据基于文本信息的矩阵分解模型预测出的用户与产品交互的概率。

[0064] 在本发明实施实例中,所述具体的训练预测函数集成模型的步骤请参阅图5。

[0065] 步骤S104,根据所述待推荐用户的隐因子向量、待推荐的隐因子向量以及利用深度学习训练出的含有确定参数的预测函数集成模型计算待推荐用户对各待推荐的产品的预测交互矩阵。

[0066] 在本发明实施实例中,所述训练结果包括用户的隐因子矩阵,即包括待推荐用户的隐因子向量,根据用户的隐因子向量以及待推荐的产品集合中各产品的特征信息,利用确定的预测函数集成模型即可计算出用户对各待推荐产品的预测交互矩阵。

[0067] 在本发明实施实例中,所述预测交互矩阵中各数值的大小可用于表示所述待推荐用户对所述各待推荐的产品偏好概率,数值越大,说明用户对所述待推荐的产品偏好概率越大,推荐的效果越好。

[0068] 步骤S105,根据所述预测交互矩阵对所述待推荐的产品集合中各产品进行排序,并将排序靠前的产品推荐给所述待推荐用户。

[0069] 本发明实施实例公开的产品推荐方法,通过将待推荐产品、与待推荐的用户有过历史交互的产品组合构成产品集,并根据产品集中各产品的多模态数据提取各产品的特殊特征信息,将与上述产品集有过历史交互的用户组合构成用户集,将产品集与用户集组合构成样本集合,根据样本集合中各用户与产品之间是否发生过交互的数据,利用深度学习训练出确定的预测函数集成模型,以及各用户的隐因子向量,在获取待推荐用户的隐因子向量以及确定的预测函数集成模型后,根据待推荐用户的隐因子向量以及待推荐产品的特征信息,利用预测函数集成模型计算出所述待推荐用户对各待推荐产品的偏好概率,从而将偏好概率较高的产品推荐给相应的用户。本发明实施实例公开的产品推荐的方法,相比于现有技术,额外获取了产品的可视化信息,包括但不限于海报、宣传画、简介、说明书等,并提取了相应的可视化图像特征信息和文本特征信息,充分利用特征信息,有效地提高了最终推荐的效果。

[0070] 图2为本发明实施实例中提取产品特征信息的步骤流程图,详述如下。

[0071] 步骤S201,利用深度残差网络处理所述待推荐的产品集合以及待推荐用户历史交互的产品集合中各产品的可视化图像信息,并提取各产品的图像信息隐因子向量。

[0072] 在本发明实施实例中,相比于一般的网络学习模型存在的增加学习层深度反而会导致效果降低(退化)的技术问题,在提供较深的学习层的同时,使得训练出来的效果也得到了提高。

[0073] 在本发明实施实例中,所述深度残差网络经过了ImageNet数据集(一个用于视觉对象识别软件研究的大型可视化数据库)的预训练,使得提取的可视化图像信息隐因子向量包括2048维。

[0074] 作为本发明的一个优选实施例,所述深度残差网络采用深度为50层的版本,不包含最后一层全连接层。

[0075] 在本发明实施例中,所述采用的深度残差网络的结构示意图请参阅图3。

[0076] 步骤S202,利用文本向量建模模型处理所述待推荐的产品集合以及待推荐用户历史交互的产品集合中各产品的文本信息,并提取各产品的文本信息因子向量。

[0077] 在本发明实施例中,所述文本向量建模模型可用于将文本信息表征为为多维度的向量表示。

[0078] 在本发明实施例中,所述文本向量建模模型经过了大量语料库上的预训练,包括了对文本特征的分词处理、去停用词、大小写转换等预处理步骤和利用文本向量建模模型提取文本特征。

[0079] 在本发明实施例中,所述模型将每个文本映射到一个固定大小的向量,最终输出300维的特征向量。

[0080] 图3为本发明实施例中采用的深度残差网络的结构示意图,现结合示意图的内容对所述深度残差网络进行解释说明。

[0081] 网络结构由Conv单元、Residual单元以及一些池化层(Polling)和展开层(Flatten)构成,顺序关系如图3所示.Conv单元包括7*7大小的卷积层(Conv2D),批量归一化层(BN)和激活层;Residual块由1*1、3*3、1*1三个Conv2D组成,并分为Identity Block及ConvBlock,其中Identity Block依次经过1*1Conv2D、BN层、激活层、3*3Conv2D、BN、激活层、1*1Conv2D、BN,并与输入叠加后,经过激活层,最终得到输出,Identity Block块保证了输入输出同尺度可实现多个块叠加.ConvBlock依次经过1*1Conv2D、BN层、激活层、3*3Conv2D、BN层、激活层、1*1Conv2D、BN层,并由输入经过1*1Conv2D、BN层后的结果进行叠加,最终经过激活层得到输出,ConvBlock块进行了尺度变换,用于分割不同的阶段网络。该网络结构输出维度为2048维的特征向量。

[0082] 图4为本发明实施例中建立的样本集合形式的示意图,详述如下。

[0083] 在本发明实施例中,所述产品呈纵列排布,用户呈横列排布。

[0084] 在本发明实施例中,所述产品与用户交界处的数据(0或1)用于表示用户是否与该产品有过交互行为,数据为0表示用户与该产品之间没有交互行为,数据为1表示用户与该产品之间有过交互行为。

[0085] 在本发明实施例中,所述样本集合中用户与产品的数量越多,则效果越好,当选取了与产品A有过交互行为的用户a时,显然,用户a也有可能与其他产品有交互行为。

[0086] 图5为本发明实施例中训练预测函数集成模型的具体步骤流程图,详述如下。

[0087] 步骤S501,按照预设的规则从所述样本集合中获取训练集合,所述训练集合包括多个用户-产品对。

[0088] 在本发明实施例中,所述训练集合相当于样本集合的一个子集,包括多个用户-产品对,由于样本集合中不存在交互关系的用户-产品对不能表示所述用户对所述产品的偏好概率为0,因此,若选用全部的样本数据用于训练,会导致误差偏大。

[0089] 作为本发明的一个优选实施例,所述训练集合包括样本集合中的全部正样本及部分负样本,所述正样本为所述样本集合中存在交互关系的用户-产品对,所述负样本为所述样本集合中不存在交互关系的用户-产品对,显然正样本可确定的表示所述用户对

所述产品的偏好概率为1,而负样本中用户对所述产品的偏好概率无法确定,因此,通过随机采样的方法获取部分负样本用于表示用户对所述产品的偏好概率为0。

[0090] 作为本发明的一个优选实施例,进一步的,所述正样本与所述负样本的比例为1:K,其中K作为超参数,更进一步的,所述K值取4。

[0091] 步骤S502,获取训练集中用户的隐因子向量以及产品的隐因子向量,并根据基于产品的隐因子向量的传统矩阵分解模型,输出第一预测交互矩阵。

[0092] 在本发明实施例中,在第一次训练时,所述获取的用户的隐因子向量以及产品的隐因子向量是从初始化的用户隐因子矩阵、产品的隐因子矩阵中获取,后续的每一次训练都是从更新调整后的用户隐因子矩阵和产品隐因子矩阵中获取。

[0093] 在本发明实施例中,所述传统矩阵分解模型详见前述步骤S103的解释说明,在此不再赘述。

[0094] 步骤S503,计算所述第一预测交互矩阵与所述训练集中用户与产品的交互矩阵的第一差异值。

[0095] 在本发明实施例中,由于用户与产品真实交互的数据R可通过样本集合获取,因此,可计算R与第一预测交互矩阵R1的第一差异值J1,其中差异值J1的表达式如下:

$$[0096] \quad J_1 = \log loss(R, R_1) + r_1 (\|U\|_F^2 + \|V\|_F^2)$$

[0097] 其中, $\log loss(y, \hat{y}) = y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})$ 中, y 和 \hat{y} 分别表示R与R1中相应位置的数据, $y = 0$ 或 1 , 而 $0 < \hat{y} < 1$, 为了防止过拟合,额外加入正则化项,正则化项采用F范数 $\|A\|_F$, 其中F范数的公式如下:

$$[0098] \quad \|A\|_F = \sqrt{\left(\sum_{i=1}^m \sum_{j=1}^n |a_{ij}|^2 \right)}$$

[0099] 在本发明实施例中,第一差异值越小,表明用户隐因子矩阵、产品隐因子矩阵越符合实际情况。

[0100] 步骤S504,获取训练集中用户的隐因子向量以及产品的图像信息隐因子向量,并根据基于可视化图像信息的矩阵分解模型,输出第二预测交互矩阵。

[0101] 在本发明实施例中,所述基于可视化图像信息的矩阵分解模型需要以用户的隐因子向量以及产品的图像信息隐因子向量为输入。

[0102] 在本发明实施例中,所述基于可视化图像信息的矩阵分解模型详见前述步骤S103的解释说明,在此不再赘述。

[0103] 步骤S505,计算所述第二预测交互矩阵与所述训练集中用户与产品的交互矩阵的第二差异值。

[0104] 在本发明实施例中,同样的,可计算R与第二预测交互矩阵R2的第二差异值J2,其中差异值J2的表达式如下:

$$[0105] \quad J_2 = \log loss(R, R_2) + r_2 \|W_2\|_F^2$$

[0106] 在本发明实施例中,所述表达式中各函数的具体内容与步骤S503相同,在此不再赘述。

[0107] 在本发明实施例中,上述差异值函数表明该模型实现真实标签与R1之间残差的建模,学习目标为在R1的基础上使预测值更接近与真实标签。

[0108] 步骤S506,获取训练集中用户的隐因子向量以及产品的文本信息隐因子向量,并根据基于文本信息的矩阵分解模型,输出第三预测交互矩阵。

[0109] 在本发明实施例中,所述基于文本信息的矩阵分解模型需要以用户的隐因子向量以及产品的文本信息隐因子向量为输入。

[0110] 在本发明实施例中,所述基于文本信息的矩阵分解模型详见前述步骤S103的解释说明,在此不再赘述。

[0111] 步骤S507,计算所述第三预测交互矩阵与所述训练集中用户与产品的交互矩阵的第三差异值。

[0112] 在本发明实施例中,同样的,可计算R与第三预测交互矩阵R3的第三差异值J3,其中差异值J3的表达式如下:

$$[0113] \quad J_3 = \log \text{loss}(R, R_3) + r_3 \|W_3\|_F^2$$

[0114] 在本发明实施例中,所述表达式中各函数的具体内容与步骤S503相同,在此不再赘述。

[0115] 在本发明实施例中,上述差异值函数表明该模型实现真实标签与R2之间残差的建模,学习目标为在R2的基础上使预测值更接近与真实标签。

[0116] 步骤S508,判断所述差异值的总和是否满足预设的要求。

[0117] 在本发明实施例中,所述预设的要求可以是所述差异值的总和小于预设的阈值,也可以是此次差异值总和相比上一次训练的差异值总和下降的幅度小于预设的阈值。

[0118] 在本发明实施例中,当判断所述差异值的总和不满预设的要求时,表明训练出的模型不符合要求,执行步骤S509;当判断所述差异值的总和满足预设的要求时,表明训练出的模型符合要求,执行步骤S510。

[0119] 步骤S509,根据所述第一差异值、第二差异值以及第三差异值的大小,利用误差反向传播算法,梯度逐级回传调整所述用户的隐因子向量、产品的隐因子向量以及所述预测函数集成模型中的可变参数。

[0120] 在本发明实施例中,当判断所述差异值的总和不满预设的要求时,根据所述第一差异值、第二差异值以及第三差异值的大小,利用误差反向传播算法,梯度逐级回传调整所述用户的隐因子向量以及所述预测函数集成模型中的可变参数,并返回至步骤S502。

[0121] 步骤S510,确定待推荐户的隐因子向量、待推荐产品的隐因子向量以及所述预测函数集成模型中的可变参数。

[0122] 在本发明实施例中,判断所述差异值的总和满足预设的要求时,即可确定用户的隐因子矩阵U、产品的隐因子矩阵V,以及基于可视化图像信息的矩阵分解模型中的可变参数W2、b2,基于文本信息的矩阵分解模型中的可变参数W3、b3。

[0123] 为了使本发明实施例中预测函数集成模型的结构更加详细具体,请参阅图6。

[0124] 图6为本发明实施例中提供的预测函数集成模型的结构示意图,详述如下。

[0125] 在本发明实施例中,请参阅图6,基学习器一即为传统矩阵分解模型,包括用户的隐因子矩阵以及产品的隐因子矩阵,基学习器二即为基于可视化图像信息的矩阵分解模型,基学习器三即为基于文本信息的矩阵分解模型。

[0126] 图7为本发明另一个实施例中产品推荐方法的步骤流程图,为了便于说明,仅示出与本发明实施例相关的部分。

[0127] 在本发明实施例中,相比于图1示出的一种产品推荐方法的步骤流程图,本发明实施例中产品推荐方法在所述步骤S104之前,还包括:

[0128] 步骤S701,根据所述样本集合以及利用深度学习训练出的含有确定参数的预测函数集成模型衡量所述含有确定参数的预测函数集成模型的推荐效果。

[0129] 在本发明实施例中,根据所述样本集合,可以方便直观的获取预测函数集成模型的推荐效果。

[0130] 在本发明实施例中,所述衡量预测函数集成模型的推荐效果的具体步骤请参阅图8。

[0131] 图8为本发明实施例提供的衡量预测函数集成模型的推荐效果的步骤流程图,详述如下。

[0132] 步骤S801,按照预设的规则对样品集中每个用户生成一个测试集合。

[0133] 在本发明实施例中,所述每个用户都有一个测试集合,所述每个用户的测试集合包括一个存在交互的关系的用户-产品对以及多个不存在交互的关系的用户-产品对。

[0134] 步骤S802,获取第一用户测试集合中所述第一用户的隐因子向量以及产品的隐因子向量。

[0135] 在本发明实施例中,所述第一用户的隐因子向量同样是从用户的隐因子矩阵中获取。

[0136] 步骤S803,根据所述第一用户的隐因子向量、第一用户测试集合中各产品的隐因子向量以及利用深度学习训练出的含有确定参数的预测函数集成模型计算所述第一用户对第一用户测试集合中各产品的测试交互矩阵。

[0137] 在本发明实施例中,述测试交互矩阵中数值的大小表示所述第一用户对相应产品的偏好的概率。

[0138] 步骤S804,根据所述测试交互矩阵对所述第一用户测试集合中各产品进行排序。

[0139] 步骤S805,统计所述第一测试集合中正样品中相应的产品在所述排序中的位置。

[0140] 在本发明实施例中,所述第一测试集合中包括一个正样本以及多个负样本,正样本在所述排序中的位置越高,说明用户与该产品有过交互行为的概率越大,这也正好符合用户与该产品存在交互行为的实际情况。

[0141] 步骤S806,根据所述统计的结果计算点击率和归一化折损累计增益,所述点击率和归一化折损累计增益可用于标识所述含有确定参数的预测函数集成模型的推荐效果。

[0142] 在本发明实施例中,所述点击率HR的计算公式如下:HR=(所有测试集合中正样本出现在前N个位置的次数)/(所有的测试集合个数),N为可预设的值,优选设置N=5,点击率越高,表明推荐效果越好。

[0143] 在本发明实施例中,所述归一化折损累计增益NDCG的计算公式如下:

$$[0144] \quad NDCG@N = \frac{1}{NUM(user)} \sum_{i=1}^{NUM(user)} hits(i)$$

$$[0145] \quad hits(i) = \begin{cases} \frac{1}{\log_2(pos_i + 1)} & \text{if } co(i) = 1 \\ 0 & \text{if } co(i) = 0 \end{cases}$$

[0146] 其中, NDCG@N中N与点击率HR中N共享, NUM(user)表示用户的个数, 即所有的测试集合个数, pos_i 表示第i个测试集合中正样本出现的位置排序, $co(i)$ 表示第i个测试集合中正样本是否出现在前N个位置, 当第i个测试集合中正样本出现在前N个位置时, $co(i) = 1$, 当第i个测试集合中正样本没有出现在前N个位置时, $co(i) = 0$ 。

[0147] 在本发明实施例中, 归一化折损累计增益NDCG越高, 表明推荐效果越好。

[0148] 图9为本发明实施例提供的一种产品推荐装置的结构示意图, 为了便于说明, 仅示出与本发明实施例相关的部分。

[0149] 在本发明实施例中, 所述产品推荐装置包括:

[0150] 产品数据采集单元901, 用于根据待推荐的产品集合以及待推荐用户历史交互的产品集合中各产品的多模态数据提取所述各产品的特征信息。

[0151] 在本发明实施例中, 所述各产品的多模态数据包括各产品的可视化图像信息以及各产品的文本信息, 进一步的, 所述产品的可视化图像信息包括如产品的海报、宣传画等可以直观获取的图像, 所述产品的文本信息包括如产品的说明书、简介、使用方法等可以直观获取的文本。

[0152] 在本发明实施例中, 与现有技术不同之处在于所述各产品的特征信息除了常规的传统分类信息外, 还包括从可视化图像信息中提取的图像信息隐因子向量以及从文本信息中提取的文本信息隐因子向量。

[0153] 样本集合生成单元902, 用于获取与所述待推荐的各产品以及所述待推荐用户历史交互的各产品有过交互关系的样本用户, 并与所述待推荐的各产品以及所述待推荐用户历史交互的各产品组合生成样品集合。

[0154] 在本发明实施例中, 待推荐用户也存在于所述样品集合中。

[0155] 在本发明实施例中, 为确认待推荐用户的兴趣特征信息, 需通过所述待推荐用户历史交互的产品的特征信息来判断。

[0156] 在本发明实施例中, 所述样本集合呈矩阵形式, 所述样本集合还包括样本用户与所述推荐的各产品以及待推荐用户历史交互的各产品之间的交互数据。

[0157] 预测函数集成模型训练单元903, 用于根据所述样本集合利用深度学习对含有可变参数的预测函数集成模型进行训练, 以确定待推荐用户的隐因子向量、待推荐产品的隐因子向量以及所述预测函数集成模型中的可变参数。

[0158] 在本发明实施例中, 所述预测函数集成模型包括基于产品隐因子向量的传统矩阵分解模型、基于可视化图像信息的矩阵分解模型以及基于文本信息的矩阵分解模型。

[0159] 在本发明实施例中, 所述基于产品隐因子向量的传统矩阵分解模型、基于可视化图像信息的矩阵分解模型以及基于文本信息的矩阵分解模型请参阅前述步骤S103的解释说明。

[0160] 预测交互矩阵计算单元904, 用于根据所述待推荐用户的隐因子向量、待推荐的隐因子向量以及利用深度学习训练出的含有确定参数的预测函数集成模型计算待推荐用户对各待推荐的产品的预测交互矩阵。

[0161] 在本发明实施例中,所述训练结果包括用户的隐因子矩阵,即包括待推荐用户的隐因子向量,根据用户的隐因子向量以及待推荐的产品集合中各产品的特征信息,利用确定的预测函数集成模型即可计算出用户对各待推荐产品的预测交互矩阵。

[0162] 在本发明实施例中,所述预测交互矩阵中各数值的大小可用于表示所述待推荐用户对所述各待推荐的产品偏好概率,数值越大,说明用户对所述待推荐的产品偏好概率越大,推荐的效果越好。

[0163] 推荐单元905,用于根据所述预测交互矩阵对所述待推荐的产品集合中各产品进行排序,并将排序靠前的产品推荐给所述待推荐用户。

[0164] 本发明实施例公开的的产品推荐装置,通过将待推荐产品、与待推荐的用户有过历史交互的产品组合构成产品集,并根据产品集中各产品的多模态数据提取各产品的特殊特征信息,将与上述产品集有过历史交互的用户组合构成用户集,将产品集与用户集组合构成样本集合,根据样本集合中各用户与产品之间是否发生过交互的数据,利用深度学习训练出确定的预测函数集成模型,以及各用户的隐因子向量,在获取待推荐用户的隐因子向量以及确定的预测函数集成模型后,根据待推荐用户的隐因子向量以及待推荐产品的特征信息,利用预测函数集成模型计算出所述待推荐用户对各待推荐产品的偏好概率,从而将偏好概率较高的产品推荐给相应的用户。本发明实施例公开的的产品推荐的方法,相比于现有技术,额外获取了产品的可视化信息,包括但不限于海报、宣传画、简介、说明书等,并提取了相应的可视化图像特征信息和文本特征信息,充分利用特征信息,有效地提高了最终推荐的效果。

[0165] 本发明实施例提供一种计算机装置,该计算机装置包括处理器,所述处理器用于执行存储器中存储的计算机程序时实现上述图1至图8所示出的实施例所提供的产品推荐方法的步骤。

[0166] 示例性的,计算机程序可以被分割成一个或多个模块,一个或者多个模块被存储在存储器中,并由处理器执行,以完成本发明。一个或多个模块可以是能够完成特定功能的一系列计算机程序指令段,该指令段用于描述计算机程序在计算机装置中的执行过程。例如,计算机程序可以被分割成上述各个方法实施例提供的产品推荐方法的步骤。

[0167] 本领域技术人员可以理解,上述计算机装置的描述仅仅是示例,并不构成对计算机装置的限定,可以包括比上述描述更多或更少的部件,或者组合某些部件,或者不同的部件,例如可以包括输入输出设备、网络接入设备、总线等。

[0168] 所称处理器可以是中央处理单元(Central Processing Unit,CPU),还可以是其他通用处理器、数字信号处理器(Digital Signal Processor,DSP)、专用集成电路(Application Specific Integrated Circuit,ASIC)、现成可编程门阵列(Field-Programmable Gate Array,FPGA)或者其他可编程逻辑器件、分立门或者晶体管逻辑器件、分立硬件组件等。通用处理器可以是微处理器或者该处理器也可以是任何常规的处理器等,所述处理器是所述计算机装置的控制中心,利用各种接口和线路连接整个计算机装置的各个部分。

[0169] 所述存储器可用于存储所述计算机程序和/或模块,所述处理器通过运行或执行存储在所述存储器内的计算机程序和/或模块,以及调用存储在存储器内的数据,实现所述计算机装置的各种功能。所述存储器可主要包括存储程序区和存储数据区,其中,存储

程序区可存储操作系统、至少一个功能所需的应用程序(比如声音播放功能、图像播放功能等)等;存储数据区可存储根据手机的使用所创建的数据(比如音频数据、电话本等)等。此外,存储器可以包括高速随机存取存储器,还可以包括非易失性存储器,例如硬盘、内存、插接式硬盘,智能存储卡(Smart Media Card,SMC),安全数字(Secure Digital,SD)卡,闪存卡(Flash Card)、至少一个磁盘存储器件、闪存器件、或其他易失性固态存储器件。

[0170] 所述计算机装置集成的模块/单元如果以软件功能单元的形式实现并作为独立的产品销售或使用,可以存储在一个计算机可读取存储介质中。基于这样的理解,本发明实现上述实施例方法中的全部或部分流程,也可以通过计算机程序来指令相关的硬件来完成,所述的计算机程序可存储于一计算机可读存储介质中,该计算机程序在被处理器执行时,可实现上述各个方法实施例的步骤。其中,所述计算机程序包括计算机程序代码,所述计算机程序代码可以为源代码形式、对象代码形式、可执行文件或某些中间形式等。所述计算机可读介质可以包括:能够携带所述计算机程序代码的任何实体或装置、记录介质、U盘、移动硬盘、磁碟、光盘、计算机存储器、只读存储器(ROM,Read-Only Memory)、随机存取存储器(RAM,Random Access Memory)、电载波信号、电信号以及软件分发介质等。

[0171] 以上所述仅为本发明的较佳实施例而已,并不用以限制本发明,凡在本发明的精神和原则之内所作的任何修改、等同替换和改进等,均应包含在本发明的保护范围之内。

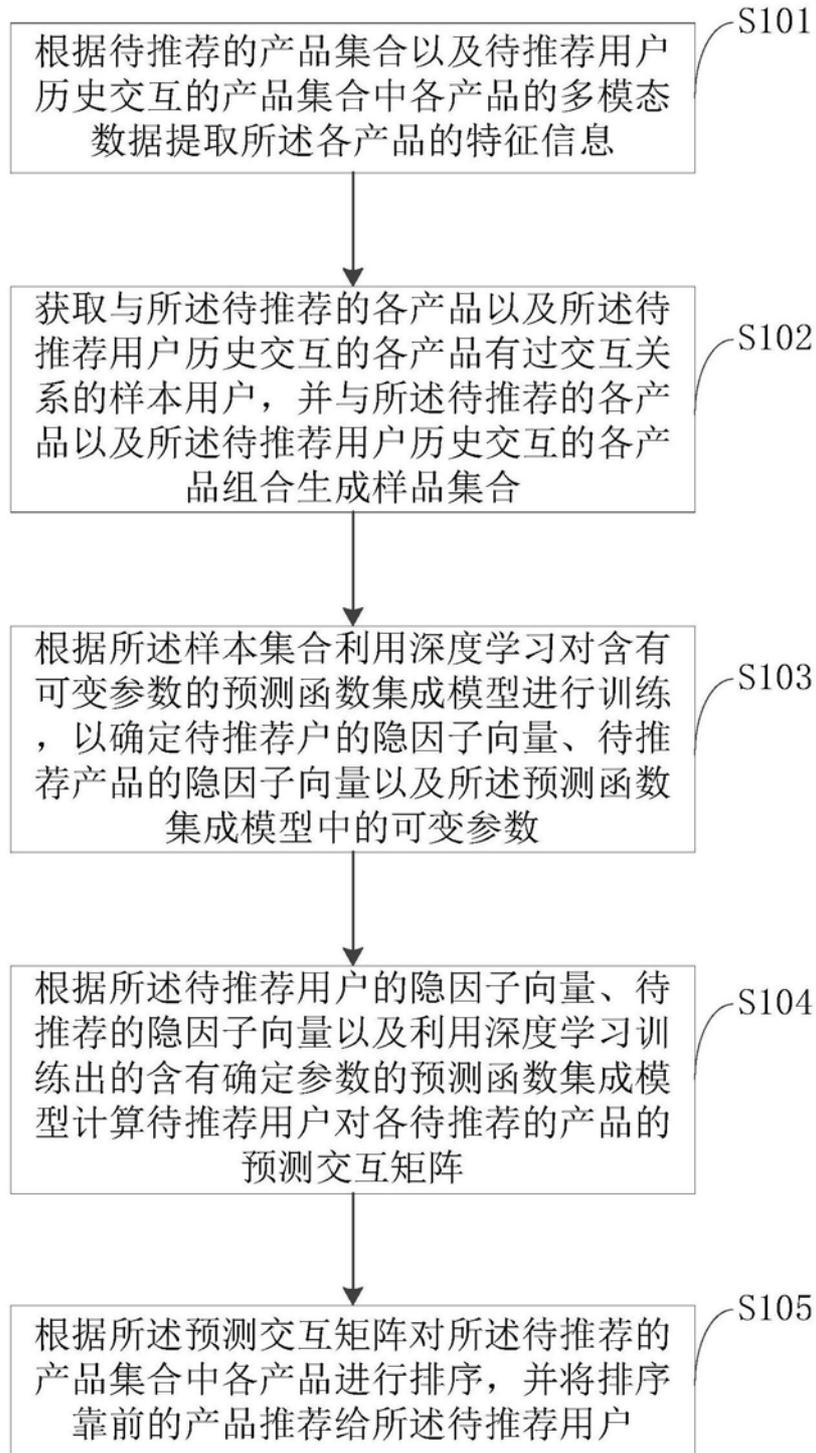


图1

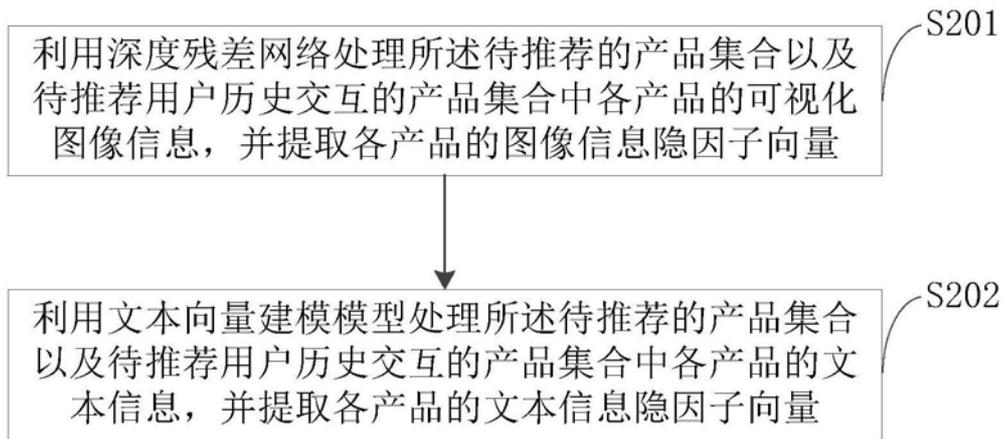


图2

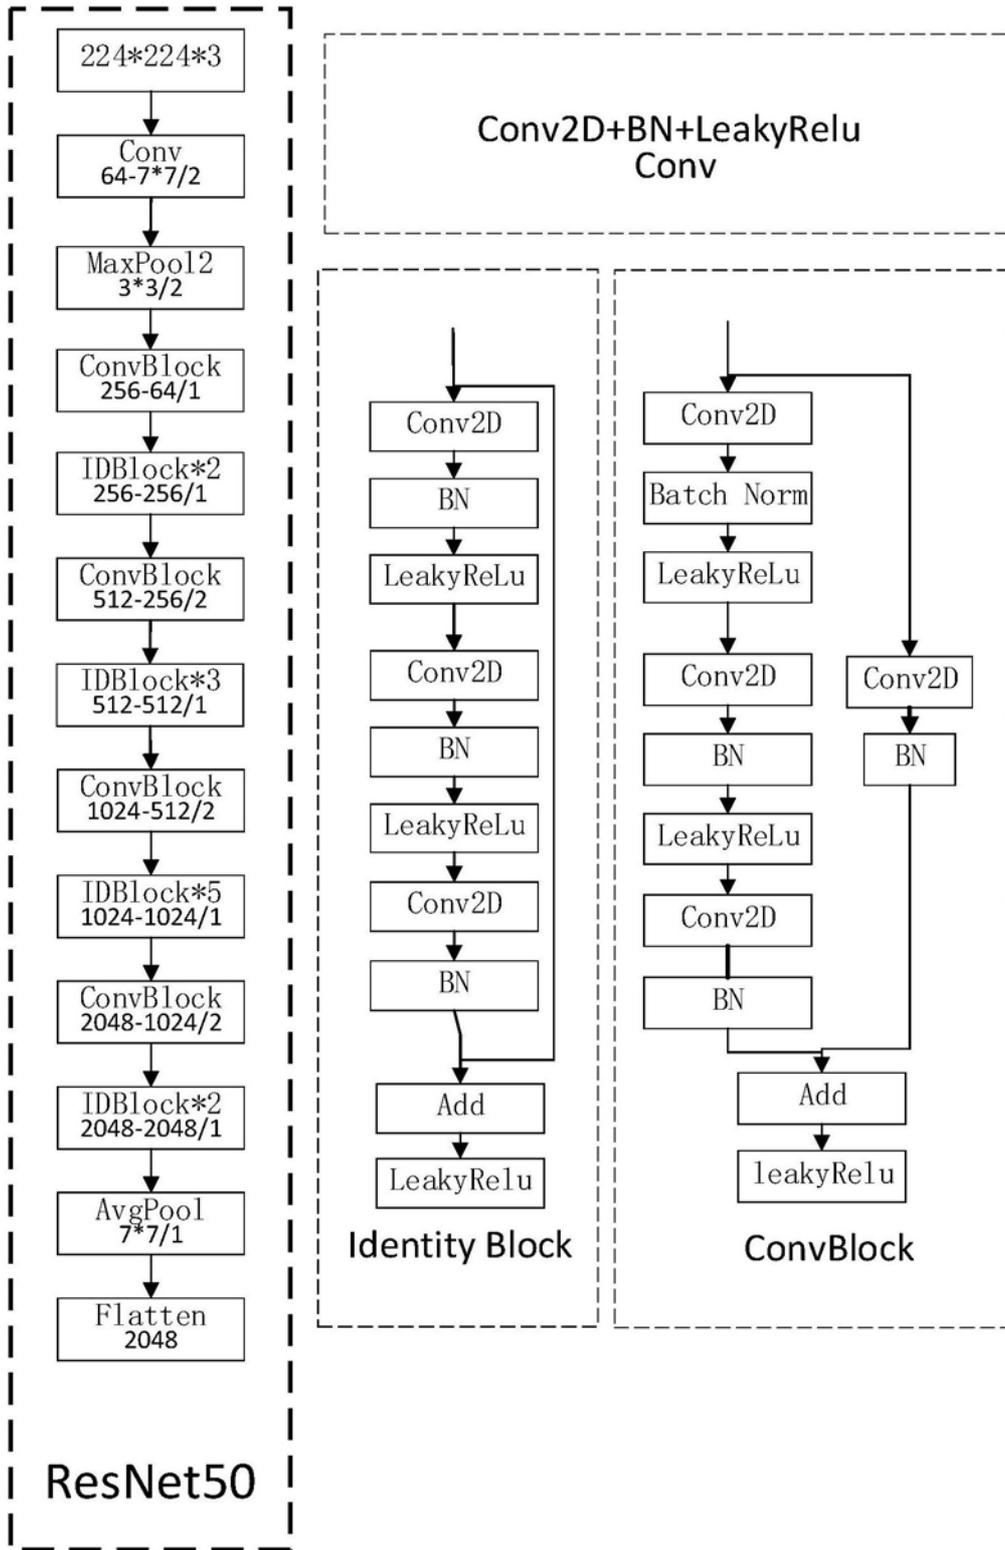


图3

产品 用户	用户 0	用户 1	用户 2	用户 3	用户 4	...	用户 m
产品 0	1	0	1	0	0		0
产品 1	1	0	0	1	1		0
产品 2	1	0	0	1	1		1
产品 3	1	1	0	1	0		0
产品 4	1	0	1	1	0		0
...							
产品 n	1	0	0	1	1	1	0

图4

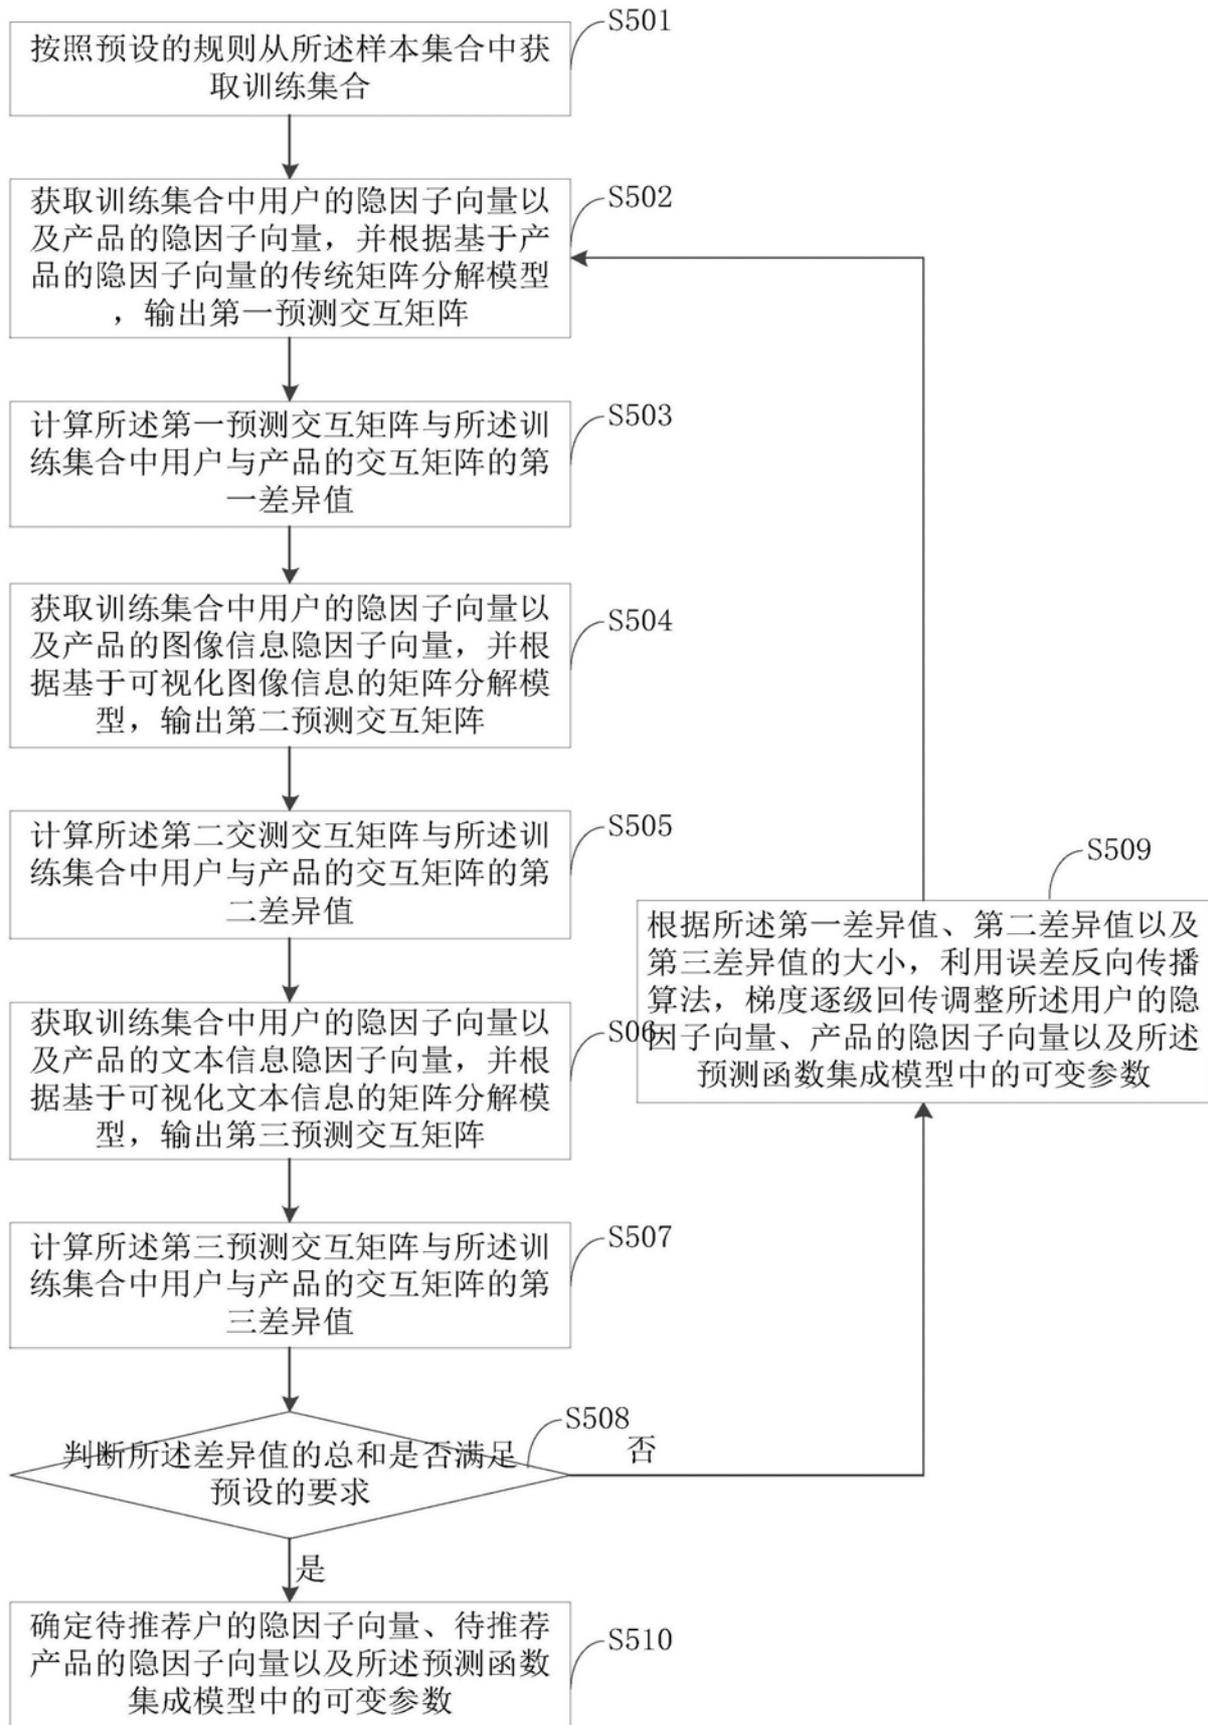


图5

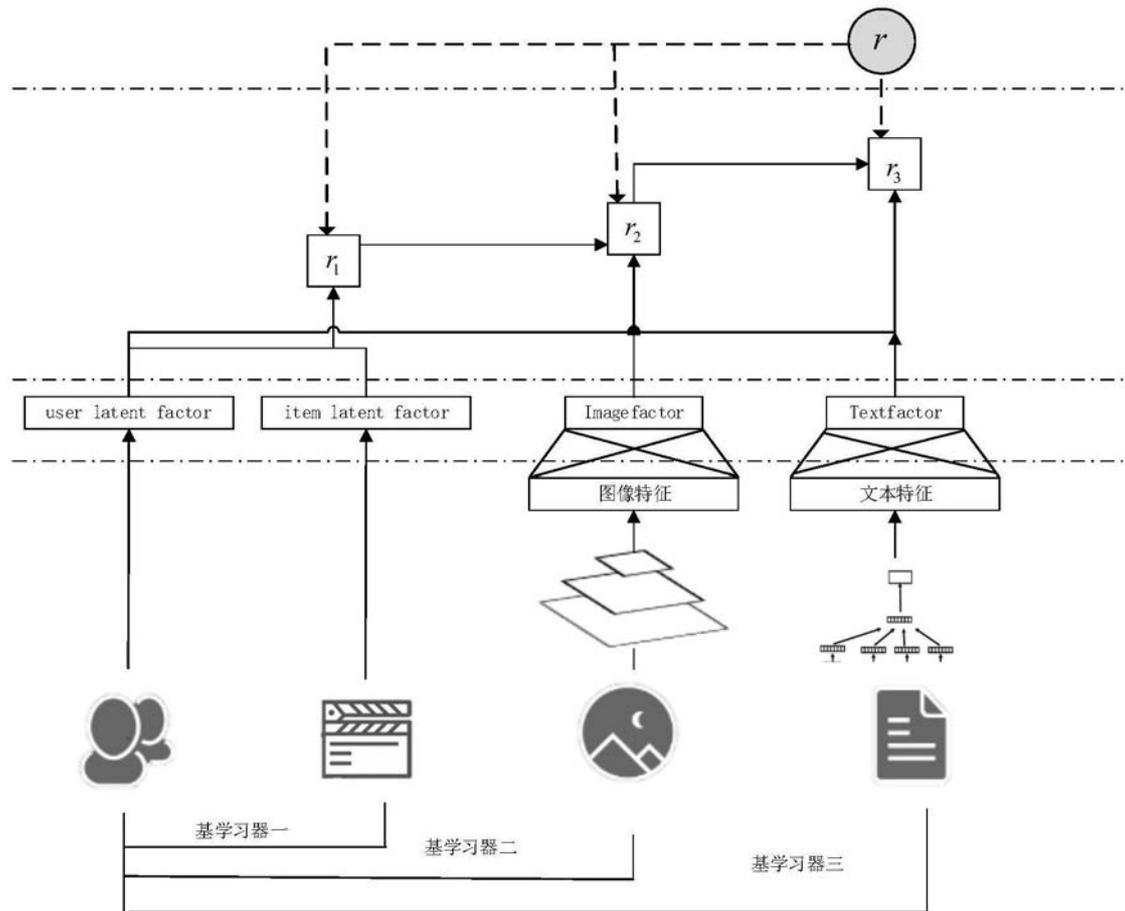


图6

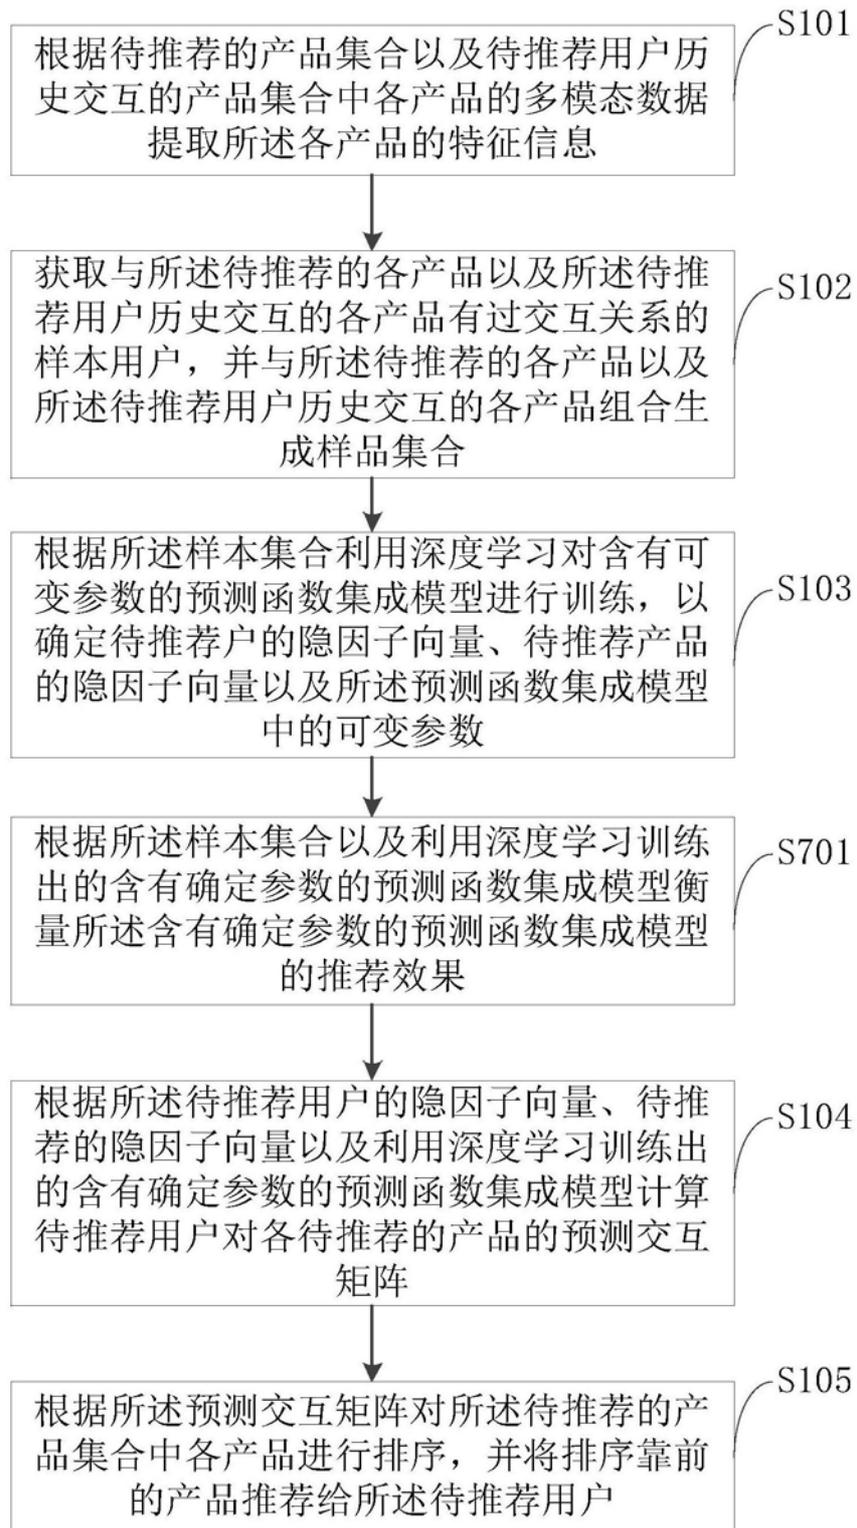


图7

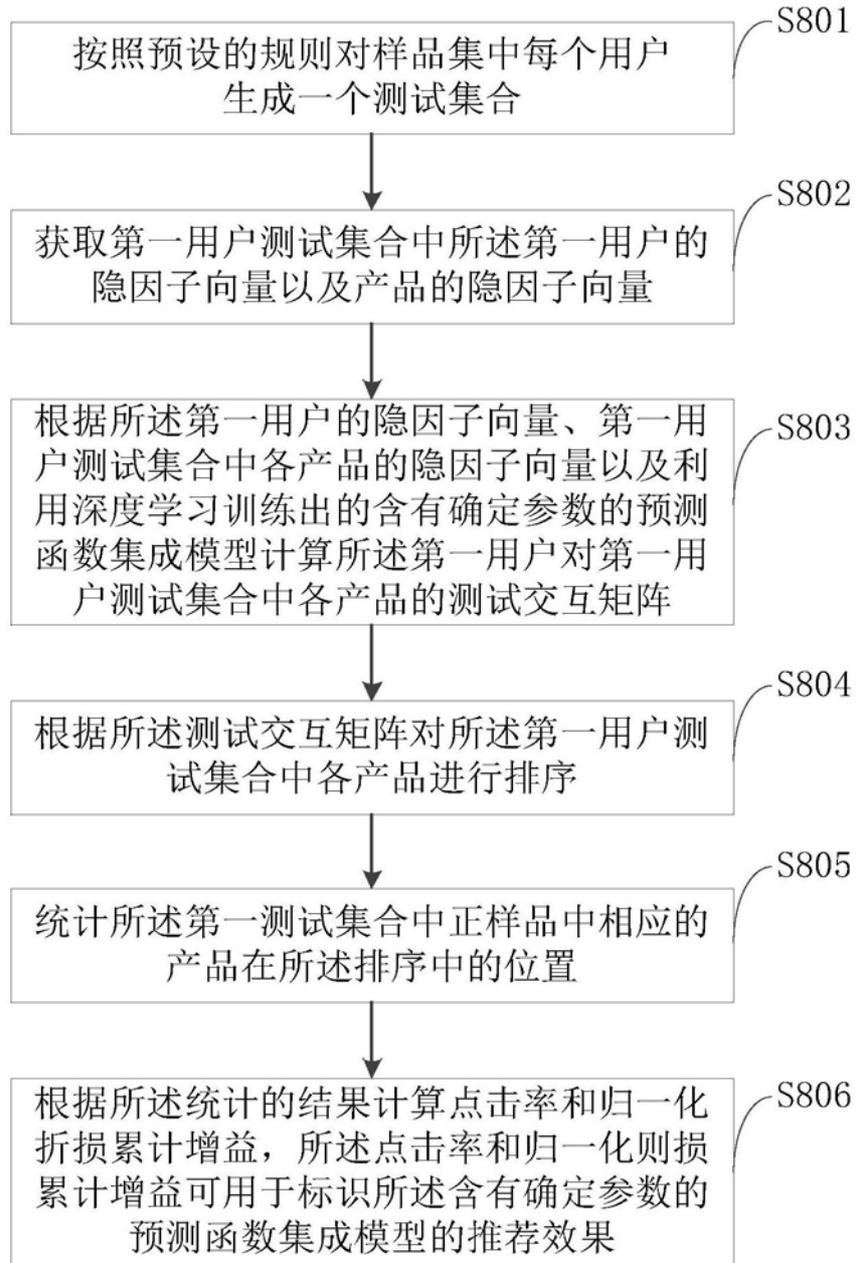


图8

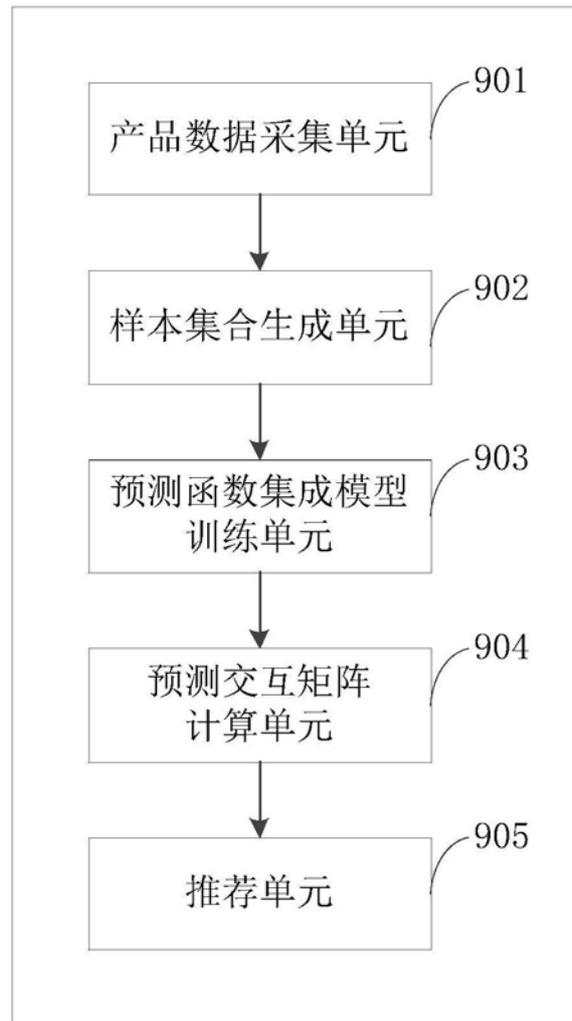


图9