

基于深度学习的推荐方法和装置、电子设备、介质、程序

本申请要求在 2018 年 01 月 10 日提交中国专利局、申请号为 CN201810024218.9、发明名称为“基于深度学习的推荐方法和装置、电子设备、介质、程序”的中国专利申请的优先权，其全部内容通过引用结合在本申请中。

技术领域

本申请涉及互联网技术，尤其是一种基于深度学习的推荐方法和装置、电子设备、介质、程序。

背景技术

推荐系统已经成为电子商务和许多在线共享服务的核心，从技术角度而言，推荐系统通常是基于内容或协同过滤产生。前者主要依靠物品的特征，而后者基于来自其他具有相似历史的用户；在现实应用中，协同过滤已经显示出很大的功效。

发明内容

本申请实施例提供一种基于深度学习的推荐技术。

根据本申请实施例的一个方面，提供一种基于深度学习的推荐方法，包括：

分别获取所述目标用户的相关信息和所述目标物品的相关信息；所述相关信息包括用于描述与用户的操作相关的，或与被操作的物品相关的任意一个或多个信息；

分别利用集成模型中的至少两个子模型，基于所述目标用户的相关信息和所述目标物品的相关信息得到至少两个所述子模型对应的操作概率；所述操作概率用于表示基于一个子模型得到的所述目标用户操作所述目标物品的概率，所述集成模型包括至少两个子模型；

基于所述至少两个子模型对应的操作概率得到所述目标用户操作所述目标物品的目标概率；

基于所述目标概率为所述目标用户推荐所述目标物品。

在基于本申请上述方法的另一个实施例中，所述目标用户的相关信息包括：所述目标用户操作历史物品的历史信息，所述历史物品包括所述目标用户操作过的至少一个物品；和/或，

所述目标物品的相关信息包括：所述目标物品被历史用户操作的历史信息，所述历史用户包括操作过所述目标物品的至少一个用户。

在基于本申请上述方法的另一个实施例中，所述分别利用集成模型中的至少两个子模型，基于所述目标用户的相关信息和所述目标物品的相关信息得到至少两个所述子模型对应的操作概率，包括：

利用所述子模型分别将所述目标用户的相关信息和所述目标物品的相关信息向量化，得到用户向量和物品向量；

基于所述用户向量和所述物品向量得到所述操作概率。

在基于本申请上述方法的另一个实施例中，基于所述用户向量和所述物品向量得到所述操作概率，包括：

计算所述用户向量与所述物品向量的点积得到操作值，基于所述操作值得到所述操作概率。

在基于本申请上述方法的另一个实施例中，基于所述至少两个子模型对应的操作概率得到所述目标用户操作所述目标物品的目标概率，包括：

分别计算所述操作概率与所述操作概率对应的子模型的模型权重值的乘积，每个所述模型权重值对应一个所述子模型；

将所述对应至少两个所述操作概率的乘积相加，得到所述目标用户操作所述目标物品的目标概率。

在基于本申请上述方法的另一个实施例中，基于所述目标概率为所述目标用户推荐所述目标物品，包括：

响应于所述目标概率大于或等于预设阈值，将所述目标概率对应的所述目标物品推荐给所述目标用户；

响应于所述目标概率小于所述预设阈值，不将所述目标概率对应的所述目标物品推荐给所述目标用户。

在基于本申请上述方法的另一个实施例中，所述集成模型经过对至少两个子模型之间的关系进行训练获得。

在基于本申请上述方法的另一个实施例中，所述集成模型的训练方法，包括：

基于历史用户和历史物品训练所述集成模型，所述历史用户对所述历史物品操作的历史概率为已知的。

在基于本申请上述方法的另一个实施例中，所述基于历史用户和历史物品训练所述集成模型，包括：

基于所述历史用户和所述历史物品，建立对应所述历史用户和所述历史物品的历史向量；

利用集成模型对所述历史向量进行分解，获得至少一个样本用户向量和至少一个样本物品向量；

基于所述样本用户向量和所述样本物品向量获得预测概率；所述预测概率表示所述集成模型预测的所述历史用户操作所述历史物品的概率；

基于所述预测概率和所述历史概率训练所述集成模型。

在基于本申请上述方法的另一个实施例中，所述利用集成模型对所述历史向量进行分解，获得至少一个样本用户向量和至少一个样本物品向量，包括：

利用初始集成模型对所述历史向量进行分解，获得至少一个样本用户向量和至少一个样本物品向量，所述初始集成模型包括一个子模型。

在基于本申请上述方法的另一个实施例中，基于所述样本用户向量和所述样本物品向量获得预测概率，包括：

利用所述初始集成模型计算所述样本用户向量和所述样本物品向量的点积，得到对应

所述历史用户点击所述历史物品的预测值，基于所述预测值得到预测概率。

在基于本申请上述方法的另一个实施例中，基于所述预测概率和所述历史概率训练所述集成模型，包括：

根据所述预测概率与所述历史概率的差值，为所述预测概率对应的所述历史用户和所述历史物品分配数据权重值；所述差值越大则所述数据权重值越大；

基于所述结合数据权重值的样本用户向量和样本物品向量迭代训练所述集成模型。

在基于本申请上述方法的另一个实施例中，基于所述结合数据权重值的样本用户向量和样本物品向量迭代训练集成模型，包括：

对初始集成模型增加一个子模型构成第一集成模型；

利用所述第一集成模型，结合所述数据权重值计算所述样本用户向量和所述样本物品向量的点积，得到对应所述历史用户点击所述历史物品的第一预测值，基于所述第一预测值得到第一预测概率；

迭代执行，根据所述第一预测概率与所述历史概率的第一差值，基于所述第一差值为所述第一集成模型中的至少两个所述子模型分配对应的模型权重值，并基于所述第一差值为所述第一预测概率对应的所述历史用户和所述历史物品分配第一数据权重值；

对所述第一集成模型增加一个子模型构成第二集成模型替代所述第一集成模型，将所述第二集成模型作为第一集成模型，利用所述第一集成模型，结合所述第一数据权重值计算所述样本用户向量和所述样本物品向量的点积，得到对应所述历史用户点击所述历史物品的第一预测值，基于所述第一预测值得到第一预测概率；直到满足预设收敛条件。

在基于本申请上述方法的另一个实施例中，所述满足预设收敛条件，包括：

所述第一预测概率与所述历史概率的第一差值小于预设差值。

根据本申请实施例的另一个方面，提供一种基于深度学习的推荐装置，包括：

信息获取单元，用于分别获取目标用户的相关信息和目标物品的相关信息；所述相关信息包括用于描述与用户的操作相关的，或与被操作的物品相关的任意一个或多个信息；

概率获取单元，用于分别利用集成模型中的至少两个子模型，基于所述目标用户的相关信息和所述目标物品的相关信息得到至少两个所述子模型对应的操作概率；所述操作概率用于表示基于一个子模型得到的所述目标用户操作所述目标物品的概率，所述集成模型包括至少两个子模型；

概率合成单元，用于基于所述至少两个子模型对应的操作概率得到所述目标用户操作所述目标物品的目标概率；

推荐单元，用于基于所述目标概率为所述目标用户推荐所述目标物品。

在基于本申请上述装置的另一个实施例中，所述目标用户的相关信息包括：所述目标用户操作历史物品的历史信息，所述历史物品包括所述目标用户操作过的至少一个物品；和/或，

所述目标物品的相关信息包括：所述目标物品被历史用户操作的历史信息，所述历史用户包括操作过所述目标物品的至少一个用户。

在基于本申请上述装置的另一个实施例中，所述概率获取单元，包括：

向量化模块，用于利用所述子模型分别将所述目标用户的相关信息和所述目标物品的相关信息向量化，得到用户向量和物品向量；

操作概率模块，用于基于所述用户向量和所述物品向量得到所述操作概率。

在基于本申请上述装置的另一个实施例中，所述操作概率模块，用于计算所述用户向量与所述物品向量的点积得到操作值，基于所述操作值得到所述操作概率。

在基于本申请上述装置的另一个实施例中，所述概率合成单元，用于分别计算所述操作概率与所述操作概率对应的子模型的模型权重值的乘积，每个所述模型权重值对应一个所述子模型；将所述对应至少两个所述操作概率的乘积相加，得到所述目标用户操作所述目标物品的目标概率。

在基于本申请上述装置的另一个实施例中，所述推荐单元，用于：

响应于所述目标概率大于或等于预设阈值，将所述目标概率对应的所述目标物品推荐给所述目标用户；

响应于所述目标概率小于所述预设阈值，不将所述目标概率对应的所述目标物品推荐给所述目标用户。

在基于本申请上述装置的另一个实施例中，所述集成模型经过对至少两个子模型之间的关系进行训练获得。

在基于本申请上述装置的另一个实施例中，还包括：

训练单元，用于基于历史用户和历史物品训练所述集成模型，所述历史用户对所述历史物品操作的历史概率为已知的。

在基于本申请上述装置的另一个实施例中，所述训练单元，包括：

向量模块，用于基于所述历史用户和所述历史物品，建立对应所述历史用户和所述历史物品的历史向量；

分解模块，用于利用集成模型对所述历史向量进行分解，获得至少一个样本用户向量和至少一个样本物品向量；

概率预测模块，用于基于所述样本用户向量和所述样本物品向量获得预测概率；所述预测概率表示所述集成模型预测的所述历史用户操作所述历史物品的概率；

模型训练模块，用于基于所述预测概率和所述历史概率训练所述集成模型。

在基于本申请上述装置的另一个实施例中，所述分解模块，用于利用初始集成模型对所述历史向量进行分解，获得至少一个样本用户向量和至少一个样本物品向量，所述初始集成模型包括一个子模型。

在基于本申请上述装置的另一个实施例中，所述概率预测模块，用于利用所述初始集成模型计算所述样本用户向量和所述样本物品向量的点积，得到对应所述历史用户点击所述历史物品的预测值，基于所述预测值得到预测概率。

在基于本申请上述装置的另一个实施例中，所述模型训练模块，包括：

权重分配模块，用于根据所述预测概率与所述历史概率的差值，为所述预测概率对应的所述历史用户和所述历史物品分配数据权重值；所述差值越大则所述数据权重值越大；

迭代训练模块，用于基于所述结合数据权重值的样本用户向量和样本物品向量迭代训

练所述集成模型。

在基于本申请上述装置的另一个实施例中，所述迭代训练模块，用于：

对初始集成模型增加一个子模型构成第一集成模型；

利用所述第一集成模型，结合所述数据权重值计算所述样本用户向量和所述样本物品向量的点积，得到对应所述历史用户点击所述历史物品的第一预测值，基于所述第一预测值得到第一预测概率；

迭代执行，根据所述第一预测概率与所述历史概率的第一差值，基于所述第一差值为所述第一集成模型中的至少两个所述子模型分配对应的模型权重值，并基于所述第一差值为所述第一预测概率对应的所述历史用户和所述历史物品分配第一数据权重值；

对所述第一集成模型增加一个子模型构成第二集成模型替代所述第一集成模型，将所述第二集成模型作为第一集成模型，利用所述第一集成模型，结合所述第一数据权重值计算所述样本用户向量和所述样本物品向量的点积，得到对应所述历史用户点击所述历史物品的第一预测值，基于所述第一预测值得到第一预测概率；直到满足预设收敛条件。

在基于本申请上述装置的另一个实施例中，所述满足预设收敛条件，包括：

所述第一预测概率与所述历史概率的第一差值小于预设差值。

根据本申请实施例的另一个方面，提供一种电子设备，包括处理器，所述处理器包括如上所述的基于深度学习的推荐装置。

根据本申请实施例的另一个方面，提供一种电子设备，包括：存储器，用于存储可执行指令；

以及处理器，用于与所述存储器通信以执行所述可执行指令从而完成如上所述的基于深度学习的推荐方法的操作。

根据本申请实施例的另一个方面，提供一种计算机存储介质，用于存储计算机可读的指令，所述指令被执行时实现如上所述的基于深度学习的推荐方法的操作。

根据本申请实施例的另一个方面，提供一种计算机程序，包括计算机可读代码，当所述计算机可读代码在设备上运行时，所述设备中的处理器执行用于实现如上所述的基于深度学习的推荐方法的指令。

基于本申请上述实施例提供一种基于深度学习的推荐方法和装置、电子设备、介质、程序，分别获取目标用户的相关信息和目标物品的相关信息；分别利用集成模型中的至少两个子模型，基于目标用户的相关信息和目标物品的相关信息得到至少两个子模型对应的操作概率；通过集成的至少两个子模型分别获得操作概率，再基于至少两个操作概率得到目标用户操作目标物品的目标概率，利用了至少两个子模型之间的互补性，使至少两个子模型专精的不同的数据分布得到互补，得到的概率值更能准确预测目标用户对目标物品点击的概率；基于目标概率为目标用户推荐目标物品。

下面通过附图和实施例，对本申请的技术方案做进一步的详细描述。

附图说明

构成说明书的一部分的附图描述了本申请的实施例，并且连同描述一起用于解释本申

请的原理。

参照附图，根据下面的详细描述，可以更加清楚地理解本申请，其中：

图 1 为本申请基于深度学习的推荐方法一个实施例的流程图；

图 2 为本申请基于深度学习的推荐方法应用的一个示例的示意图；

图 3 为本申请基于深度学习的推荐方法中训练集成模型的一个示例的示意图；

图 4 为本申请基于深度学习的推荐装置一个实施例的结构示意图；

图 5 为用来实现本申请实施例的终端设备或服务器的电子设备的结构示意图。

具体实施方式

现在将参照附图来详细描述本申请的各种示例性实施例。应注意到：除非另外说明，否则在这些实施例中阐述的部件和操作的相对布置、数字表达式和数值不限制本申请的范围。

同时，应当明白，为了便于描述，附图中所示出的各个部分的尺寸并不是按照实际的比例关系绘制的。

以下对至少一个示例性实施例的描述实际上仅仅是说明性的，决不作为对本申请及其应用或使用的任何限制。

对于相关领域普通技术人员已知的技术、方法和设备可能不作详细讨论，但在适当情况下，所述技术、方法和设备应当被视为说明书的一部分。

应注意到：相似的标号和字母在下面的附图中表示类似项，因此，一旦某一项在一个附图中被定义，则在随后的附图中不需要对其进行进一步讨论。

本申请实施例可以应用于终端设备、计算机系统、服务器等电子设备，其可与众多其它通用或专用计算系统环境或配置一起操作。适于与终端设备、计算机系统、服务器等电子设备一起使用的众所周知的终端设备、计算系统、环境和/或配置的例子包括但不限于：个人计算机系统、服务器计算机系统、瘦客户机、厚客户机、手持或膝上设备、基于微处理器的系统、机顶盒、可编程消费电子产品、网络个人电脑、小型计算机系统、大型计算机系统和包括上述任何系统的分布式云计算技术环境，等等。

终端设备、计算机系统、服务器等电子设备可以在由计算机系统执行的计算机系统可执行指令（诸如程序模块）的一般语境下描述。通常，程序模块可以包括例程、程序、目标程序、组件、逻辑、数据结构等等，它们执行特定的任务或者实现特定的抽象数据类型。计算机系统/服务器可以在分布式云计算环境中实施，分布式云计算环境中，任务是由通过通信网络链接的远程处理设备执行的。在分布式云计算环境中，程序模块可以位于包括存储设备的本地或远程计算系统存储介质上。

图 1 为本申请基于深度学习的推荐方法一个实施例的流程图。如图 1 所示，该实施例方法包括：

操作 101，分别获取目标用户的相关信息和目标物品的相关信息。

其中，相关信息包括用于描述与用户的操作相关的，或与被操作物品相关的任意一个或多个信息。

在一个或多个可选的实施例中，目标用户的相关信息可以包括但不限于：目标用户操作历史物品的历史信息，历史物品包括目标用户操作过的至少一个物品；目标物品的相关信息可以包括但不限于：目标物品被历史用户操作的历史信息，历史用户包括操作过目标物品的至少一个用户。本实施例可以仅通过用户的操作历史信息和物品被操作的历史信息为用户推荐用户感兴趣的物品，而不需要获取用户和物品的属性信息等，简化了信息处理的过程，提高了推荐的速度。

可选地，在某一网站（如：视频网站或购物网站等）中，当需要为目标用户推荐物品（如：商品或视频等）时，此时存在两种情况，一种：目标用户为该网站的旧用户（在该网站中进行过点击某些物品的操作），此时为该目标用户推荐的目标物品根据物品的种类和用户的购物习惯等，可以为该目标用户操作过的物品，也可以为该目标用户没有操作过的物品，此时需要获得目标用户的历史操作信息；另一种：目标用户为该网站的新用户（在该网站中未进行点击某些物品的操作），此时为该目标用户推荐在该网站上被别的用户操作过的物品，此时需要获得目标物品的历史操作信息。

在一个可选示例中，该操作 101 可以由处理器调用存储器存储的相应指令执行，也可以由被处理器运行的信息获取单元 41 执行。

操作 102，分别利用集成模型中的至少两个子模型，基于目标用户的相关信息和目标物品的相关信息得到至少两个子模型对应的操作概率。

其中，操作概率用于表示基于一个子模型得到的目标用户操作目标物品的概率，集成模型包括至少两个子模型，集成模型经过训练获得，对集成模型的训练是对至少两个子模型之间的关系的训练，通过训练后的至少两个子模型可分别得到操作概率。

在一个可选示例中，该操作 102 可以由处理器调用存储器存储的相应指令执行，也可以由被处理器运行的概率获取单元 42 执行。

操作 103，基于至少两个子模型对应的操作概率得到目标用户操作目标物品的目标概率。

可选地，通过训练后的至少两个子模型之间的关系，例如：至少两个子模型所对应的权重，结合权重将基于至少两个子模型获得的操作概率合并获得目标概率；通过多个子模型的集成，提高了集成模型的准确率。

在一个可选示例中，该操作 103 可以由处理器调用存储器存储的相应指令执行，也可以由被处理器运行的概率合成单元 43 执行。

操作 104，基于目标概率为目标用户推荐目标物品。

在一个可选示例中，该操作 104 可以由处理器调用存储器存储的相应指令执行，也可以由被处理器运行的推荐单元 44 执行。

基于本申请上述实施例提供的一种基于深度学习的推荐方法，接收目标用户和目标物品，分别获取目标用户和目标物品的相关信息；分别利用集成模型中的至少两个子模型，基于目标用户的相关信息和目标物品的相关信息得到至少两个子模型对应的操作概率；通过集成的至少两个子模型分别获得操作概率，再基于至少两个操作概率得到目标用户操作目标物品的目标概率，利用了至少两个子模型之间的互补性，使至少两个子模型专精的不

同的数据分布得到互补，得到的概率值更能准确预测目标用户对目标物品点击的概率；基于目标概率为目标用户推荐目标物品。

本申请基于深度学习的推荐方法的另一个实施例中，在上述至少一个实施例的基础上，操作 102 包括：

利用子模型分别将目标用户的相关信息和目标物品的相关信息向量化，得到用户向量和物品向量；

基于用户向量和物品向量得到操作概率。可选地，通过计算用户向量与物品向量的点积得到操作值，基于操作值得到操作概率。

可选地，本实施例中的子模型可以采用 WMF (weighted matrix factorization) 加权矩阵分解实现，为了实现概率计算，首先通过训练后的子模型将目标用户的相关信息和目标物品的相关信息分别进行向量化，向量化的维度由训练后的子模型决定，向量化后的用户向量和物品向量满足执行点积操作的需要，通过计算用户向量与物品向量的点积，得到操作值，此时操作值是一个数值，为了得到概率值，可以对操作值执行归一化等处理，以得到操作概率。

本申请基于深度学习的推荐方法的又一个实施例中，在上述至少一个实施例的基础上，操作 103，包括：

分别计算操作概率与操作概率对应的子模型的模型权重值的乘积，每个模型权重值对应一个子模型；

将对应至少两个操作概率的乘积相加，得到目标用户操作目标物品的目标概率。

可选地，通过训练为每个子模型分配一个适合的模型权重值，通过模型权重值控制每个子模型获得的操作概率在总体的目标概率中所占的比例，权重越大说明该子模型对物品推荐起到的作用越大。

在一个或多个可选实施例中，操作 104 可以包括：

响应于目标概率大于或等于预设阈值，将目标概率对应的目标物品推荐给目标用户；

响应于目标概率小于预设阈值，不将目标概率对应的目标物品推荐给目标用户。

本实施例的基于深度学习的推荐方法中，最终的目的是将目标用户更感兴趣的目标物品推荐给用户，因此，当目标概率大于或等于预设阈值，说明该目标用户点击该目标物品的概率大于或等于预设阈值，将该目标物品推荐给该目标用户可有效提升用户操作的概率，已达到有效推荐的目的。

图 2 为本申请基于深度学习的推荐方法应用的一个示例的示意图。如图 2 所示，每一个用户 users 在各子模型中都对应一个向量表示，即 embedding，同样每一个物品 items 在各子模型中也对应一个 embedding。一对用户和物品对应的向量的内积即为当前子模型给出的预测概率，即 prediction，图中通过 $P(r|u_1, v_1)$ ， $P(r|u_2, v_2)$ ， $\dots P(r|u_n, v_n)$ 表示；多个子模型的 prediction 加权相加即可得到最后的目标概率 final prediction，图中 α_1 ， α_2 ， $\dots \alpha_n$ 分别代表每个子模型对应的模型权重值，各子模型得到的预测概率结合模型权重值加权相加得到目标概率。

本申请基于深度学习的推荐方法的还一个实施例中，在上述至少一个实施例的基础上，

还包括:

基于历史用户和历史物品训练集成模型。

其中,历史用户对历史物品操作的历史概率为已知的。

在一个或多个可选的实施例中,为了获得更准确的目标概率,在应用集成模型之前,需要对集成模型进行训练,训练应用的信息是基于已知操作信息的历史用户和历史物品,通过分析历史用户和历史物品的操作信息,可实现为历史用户中的任意一个用户推荐新加入的一个或多个物品,和/或实现将任意一个或多个历史物品推荐给一个或多个新的用户。

在本申请基于深度学习的推荐方法上述至少一个实施例的一个示例中,基于历史用户和历史物品训练集成模型,包括:

基于历史用户和历史物品,建立对应历史用户和历史物品的历史向量;

利用集成模型对历史向量进行分解,获得至少一个样本用户向量和至少一个样本物品向量;

基于样本用户向量和样本物品向量获得预测概率;预测概率表示集成模型预测的历史用户操作历史物品的概率;

基于预测概率和历史概率训练集成模型。

本实施例中,由于已知历史用户和历史物品的操作信息,因此,可基于历史用户对哪些历史物品进行了操作和基于历史物品接收了哪些历史用户的操作建立矩阵向量,将历史用户作为横坐标(或纵坐标),将历史物品作为纵坐标(或横坐标),其中存在操作关系的对应历史用户和历史物品之间存在数值,该数值的大小由操作信息决定。不存在操作关系的对应历史用户和历史物品之间的数值可设置为0。

在本申请基于深度学习的推荐方法上述至少一个实施例的一个示例中,利用集成模型对历史向量进行分解,获得至少一个样本用户向量和至少一个样本物品向量,基于样本用户向量和样本物品向量获得预测概率,包括:

利用初始集成模型对历史向量进行分解,获得至少一个样本用户向量和至少一个样本物品向量,初始集成模型包括一个子模型。

利用初始集成模型计算样本用户向量和样本物品向量的点积,得到对应历史用户点击历史物品的预测值,基于预测值得到预测概率。

可选地,训练集成模型的过程是逐个子模型进行训练,初始集成模型仅包括一个子模型,对该子模型进行训练,以得到预测概率与已知的历史概率为训练集成模型的数据分配不同的数据权重值,根据分配不同的数据权重值的历史用户和历史物品训练增加一个子模型的新的集成模型,再通过新的预测概率分配新的数据权重值,迭代训练,每次重新分配历史用户和历史物品的数据权重值,直到达到收敛,并且,本实施例无需预先限制迭代次数,可一直训练到集成模型收敛或计算资源用尽,通常本实施例在前几次迭代中就能得到较好的效果。

图3为本申请基于深度学习的推荐方法中训练集成模型的一个示例的示意图。如图3所示,本示例中输入为所有历史用户和所有历史商品的操作信息,以此得到的历史向量(在图3中以 R 表示),输出为用户、物品经过集成模型分解得到的向量 embedding (在图3

中以 U 、 V 表示), 以及最终的预测概率 (在图 3 中以 P 表示, 包括: $P_0, P_1, P_2, \dots, P_n$), 在每一轮迭代训练中, 将已有集成模型给出的 prediction 与原始评分矩阵 R 进行对比, 给误差大的预测概率更高的训练权重, 按照求得的训练权重训练出一个新的子模型, 即新的 U_i 、 V_i ; 随后将新的子模型给出的 prediction 加入集成 P 中, 以此迭代。

在一个或多个可选的实施例中, 基于预测概率和历史概率训练集成模型, 包括:

根据预测概率与历史概率的差值, 为预测概率对应的历史用户和历史物品分配数据权重值; 差值越大则数据权重值越大;

基于结合数据权重值的样本用户向量和样本物品向量迭代训练集成模型。

通过每次重新分配的数据权重值结合样本用户向量和样本物品向量训练集成模型, 每次分配数据权重值将差值越大的历史用户和/或历史物品分配越大的权重值。

在一个或多个可选的实施例中, 迭代训练集成模型的过程包括:

对初始集成模型增加一个子模型构成第一集成模型;

利用第一集成模型, 结合数据权重值计算样本用户向量和样本物品向量的点积, 得到对应历史用户点击历史物品的第一预测值, 基于第一预测值得到第一预测概率;

迭代执行, 根据第一预测概率与历史概率的第一差值, 基于第一差值为第一集成模型中的至少两个子模型分配对应的模型权重值, 并基于第一差值为第一预测概率对应的历史用户和历史物品分配第一数据权重值;

对第一集成模型增加一个子模型构成第二集成模型替代第一集成模型, 将第二集成模型作为第一集成模型, 利用第一集成模型, 结合第一数据权重值计算样本用户向量和样本物品向量的点积, 得到对应历史用户点击历史物品的第一预测值, 基于第一预测值得到第一预测概率; 直到满足预设收敛条件。

可选地, 迭代训练集成模型的过程中, 可以将每次迭代的过程通过公式 (1) 表示:

$$p_{\alpha}(r|i, j) = (1 - \alpha)p(r|i, j) + \alpha p'(r|i, j) \quad \text{公式 (1)}$$

其中, $p_{\alpha}(r|i, j)$ 为新结合的集成模型输出的预测概率; $p(r|i, j)$ 为当前集成模型输出的预测概率 (为用户 i 为物品 j 操作次数为 r 的概率), $(1 - \alpha)$ 为当前集成模型对应的模型权重; $p'(r|i, j)$ 为新增子模型输出的预测概率, α 为该新增子模型对应的模型权重。例如, 当当前集成模型为初始集成模型时, 新结合的集成模型为第一集成模型; 当当前集成模型为第一集成模型时, 新结合的集成模型为第二集成模型。

每次迭代训练除了调整子模型的模型权重, 还根据预测概率和历史概率的差值调整历史用户和历史物品对应的数据权重, 数据权重的计算公式如公式 (2) 所示:

$$\rho_{ij} = \frac{\alpha \bar{P}}{\alpha \bar{P} + (1 - \alpha) P(r|i, j)} \quad \text{公式 (2)}$$

其中, ρ_{ij} 为数据权重, $\bar{P} = \iint p'(r|u, v) p_0(u) p_0(v) du dv$ 表示 $p'(r|u, v)$ 的积分, 其中 i 、 j 为编号, 表示第 i 个用户和第 j 个物品, u 是用户对应的向量, v 是物品对应的向量, 通过 $\bar{P}$ 的积分公式可推导出 $\bar{P} = p'(r|i, j)$, 因此, 公式 (2) 可转换为公式 (3):

$$\rho_{ij} = \frac{1}{1 + \gamma p(r|i, j)} \quad \text{公式 (3)}$$

其中, $\gamma = \frac{1-\alpha}{\alpha P}$ 为设定参数, 因此, 数据权重大小由当前集成模型决定, 每次集成模型变化, 数据权重随之变化。

可选的, 满足预设收敛条件, 包括:

迭代执行获得的第一预测概率与历史概率的第一差值小于预设差值。预设收敛条件还可以包括计算资源用尽。

本申请实施例提供的任一种基于深度学习的推荐方法可以由任意适当的具有数据处理能力的设备执行, 包括但不限于: 终端设备和服务器等。或者, 本申请实施例提供的任一种基于深度学习的推荐方法可以由处理器执行, 如处理器通过调用存储器存储的相应指令来执行本申请实施例提及的任一种图像处理方法。下文不再赘述。

本领域普通技术人员可以理解: 实现上述方法实施例的全部或部分操作可以通过程序指令相关的硬件来完成, 前述的程序可以存储于一计算机可读取存储介质中, 该程序在执行时, 执行包括上述方法实施例的操作; 而前述的存储介质包括: ROM、RAM、磁碟或者光盘等至少一个种可以存储程序代码的介质。

图 4 为本申请基于深度学习的推荐装置一个实施例的结构示意图。该实施例的装置可用于实现本申请上述至少一个方法实施例。如图 4 所示, 该实施例的装置包括:

信息获取单元 41, 用于分别获取目标用户的相关信息和目标物品的相关信息。

其中, 相关信息包括用于描述与用户的操作相关的, 或与被操作的物品相关的一个或多个信息。

在一个或多个可选的实施例中, 目标用户的相关信息可以包括但不限于: 目标用户操作历史物品的历史信息, 历史物品包括目标用户操作过的至少一个物品; 目标物品的相关信息可以包括但不限于: 目标物品被历史用户操作的历史信息, 历史用户包括操作过目标物品的至少一个用户。本实施例可以仅通过用户的操作历史信息和物品被操作的历史信息为用户推荐用户感兴趣的物品, 而不需要获取用户和物品的属性信息等, 简化了信息处理的过程, 提高了推荐的速度。

概率获取单元 42, 用于分别利用集成模型中的至少两个子模型, 基于目标用户的相关信息和目标物品的相关信息得到至少两个子模型对应的操作概率。

其中, 操作概率用于表示基于一个子模型得到的目标用户操作目标物品的概率, 集成模型包括至少两个子模型, 集成模型经过对至少两个子模型之间的关系进行训练获得。

概率合成单元 43, 用于基于至少两个子模型对应的操作概率得到目标用户操作目标物品的目标概率。

推荐单元 44, 用于基于目标概率为目标用户推荐目标物品。

基于本申请上述实施例提供的一种基于深度学习的推荐装置, 接收目标用户和目标物品, 分别获取目标用户和目标物品的相关信息; 分别利用集成模型中的至少两个子模型, 基于目标用户的相关信息和目标物品的相关信息得到至少两个子模型对应的操作概率; 通过集成的至少两个子模型分别获得操作概率, 再基于至少两个操作概率得到目标用户操作目标物品的目标概率, 利用了至少两个子模型之间的互补性, 使至少两个子模型专精的不同的数据分布得到互补, 得到的概率值更能准确预测目标用户对目标物品点击的概率; 基

于目标概率为目标用户推荐目标物品。

本申请基于深度学习的推荐装置的另一个实施例中，在上述至少一个实施例的基础上，概率获取单元 42，包括：

向量化模块，用于利用子模型分别将目标用户的相关信息和目标物品的相关信息进行向量化，得到用户向量和物品向量；

操作概率模块，用于基于用户向量和物品向量得到操作概率。

可选地，本实施例中的子模型可以采用 WMF (weighted matrix factorization) 加权矩阵分解实现，为了实现概率计算，首先通过训练后的子模型将目标用户的相关信息和目标物品的相关信息分别进行向量化，向量化的维度由训练后的子模型决定，向量化后的用户向量和物品向量满足执行点积操作的需要，通过计算用户向量与物品向量的点积，得到操作值，此时操作值是一个数值，为了得到概率值，可以对操作值执行归一化等处理，以得到操作概率。

可选地，操作概率模块，用于计算用户向量与物品向量的点积得到操作值，基于操作值得到操作概率。

本申请基于深度学习的推荐装置的又一个实施例中，在上述至少一个实施例的基础上，概率合成单元 43，用于分别计算操作概率与操作概率对应的子模型的模型权重值的乘积，每个模型权重值对应一个子模型；将对应至少两个操作概率的乘积相加，得到目标用户操作目标物品的目标概率。

可选地，通过训练会为每个子模型分配一个适合的模型权重值，通过模型权重值控制每个子模型获得的操作概率在总体的目标概率中所占的比例，权重越大说明该子模型对物品推荐起到的作用越大。

在一个或多个可选实施例中，推荐单元 44，用于：

响应于目标概率大于或等于预设阈值，将目标概率对应的目标物品推荐给目标用户；

响应于目标概率小于预设阈值，不将目标概率对应的目标物品推荐给目标用户。

本申请基于深度学习的推荐装置的还一个实施例中，在上述至少一个实施例的基础上，还包括：

训练单元，用于基于历史用户和历史物品训练集成模型。

其中，历史用户对历史物品操作的历史概率为已知的。

在一个或多个可选的实施例中，为了获得更准确的目标概率，在应用集成模型之前，需要对集成模型进行训练，训练应用的信息是基于已知操作信息的历史用户和历史物品，通过分析历史用户和历史物品的操作信息，可实现为历史用户中的任意一个用户推荐新加入的一个或多个物品，和/或实现将任意一个或多个历史物品推荐给一个或多个新的用户。

在本申请基于深度学习的推荐装置上述至少一个实施例的一个示例中，训练单元，包括：

向量模块，用于基于历史用户和历史物品，建立对应历史用户和历史物品的历史向量；

分解模块，用于利用集成模型对历史向量进行分解，获得至少一个样本用户向量和至少一个样本物品向量；

概率预测模块，用于基于样本用户向量和样本物品向量获得预测概率；预测概率表示集成模型预测的历史用户操作历史物品的概率；

模型训练模块，用于基于预测概率和历史概率训练集成模型。

本实施例中，由于已知历史用户和历史物品的操作信息，因此，可基于历史用户对哪些历史物品进行了操作和基于历史物品接收了哪些历史用户的操作建立矩阵向量，将历史用户作为横坐标（或纵坐标），将历史物品作为纵坐标（或横坐标），其中存在操作关系的对应历史用户和历史物品之间存在数值，该数值的大小由操作信息决定。不存在操作关系的对应历史用户和历史物品之间的数值可设置为0。

在本申请基于深度学习的推荐装置上述至少一个实施例的一个示例中，分解模块，用于利用初始集成模型对历史向量进行分解，获得至少一个样本用户向量和至少一个样本物品向量，初始集成模型包括一个子模型。

在本申请基于深度学习的推荐装置上述至少一个实施例的一个示例中，概率预测模块，用于利用初始集成模型计算样本用户向量和样本物品向量的点积，得到对应历史用户点击历史物品的预测值，基于预测值得到预测概率。

在本申请基于深度学习的推荐装置上述至少一个实施例的一个示例中，模型训练模块，包括：

权重分配模块，用于根据预测概率与历史概率的差值，为预测概率对应的历史用户和历史物品分配数据权重值；差值越大数据则权重值越大；

迭代训练模块，用于基于结合数据权重值的样本用户向量和样本物品向量迭代训练集成模型。

在本申请基于深度学习的推荐装置上述至少一个实施例的一个示例中，迭代训练模块，用于：

对初始集成模型增加一个子模型构成第一集成模型；

利用第一集成模型，结合数据权重值计算样本用户向量和样本物品向量的点积，得到对应历史用户点击历史物品的第一预测值，基于第一预测值得到第一预测概率；

迭代执行，根据第一预测概率与历史概率的第一差值，基于第一差值为第一集成模型中的至少两个子模型分配对应的模型权重值，并基于第一差值为第一预测概率对应的历史用户和历史物品分配第一数据权重值；

对第一集成模型增加一个子模型构成第二集成模型替代第一集成模型，将第二集成模型作为第一集成模型，利用第一集成模型，结合第一数据权重值计算样本用户向量和样本物品向量的点积，得到对应历史用户点击历史物品的第一预测值，基于第一预测值得到第一预测概率；直到满足预设收敛条件。

在一个或多个可选的实施例中，满足预设收敛条件，包括：

迭代执行获得的第一预测概率与历史概率的第一差值小于预设差值。

根据本申请实施例的一个方面，提供一种电子设备，包括处理器，处理器包括上述任一实施例的基于深度学习的推荐装置。

根据本申请实施例的一个方面，提供一种电子设备，包括：存储器，用于存储可执

行指令；

以及处理器，用于与存储器通信以执行可执行指令从而完成本申请基于深度学习的推荐方法上述任一实施例的操作。

根据本申请实施例的一个方面，提供一种计算机存储介质，用于存储计算机可读取的指令，指令被执行时实现本申请基于深度学习的推荐方法上述任一实施例的操作。

根据本申请实施例的一个方面，提供一种计算机程序，包括计算机可读代码，当计算机可读代码在设备上运行时，该设备中的处理器执行用于实现本申请基于深度学习的推荐方法任意一项实施例的指令。

本申请实施例还提供了一种电子设备，例如可以是移动终端、个人计算机（PC）、平板电脑、服务器等。下面参考图 5，其示出了适于用来实现本申请实施例的终端设备或服务器的电子设备 500 的结构示意图：如图 5 所示，计算机系统 500 包括一个或多个处理器、通信部等，所述一个或多个处理器例如：一个或多个中央处理单元（CPU）501，和/或一个或多个图像处理器（GPU）513 等，处理器可以根据存储在只读存储器（ROM）502 中的可执行指令或者从存储部分 508 加载到随机访问存储器（RAM）503 中的可执行指令而执行各种适当的动作和处理。通信部 512 可包括但不限于网卡，所述网卡可包括但不限于 IB（Infiniband）网卡。

处理器可与只读存储器 502 和/或随机访问存储器 530 中通信以执行可执行指令，通过总线 504 与通信部 512 相连、并经通信部 512 与其他目标设备通信，从而完成本申请实施例提供的任一项方法对应的操作，例如，分别获取目标用户的相关信息和目标物品的相关信息；分别利用集成模型中的至少两个子模型，基于目标用户的相关信息和目标物品的相关信息得到至少两个子模型对应的操作概率；基于至少两个子模型对应的操作概率得到目标用户操作目标物品的目标概率；基于目标概率为目标用户推荐目标物品。

此外，在 RAM 503 中，还可存储有装置操作所需的各种程序和数据。CPU501、ROM502 以及 RAM503 通过总线 504 彼此相连。在有 RAM503 的情况下，ROM502 为可选模块。RAM503 存储可执行指令，或在运行时向 ROM502 中写入可执行指令，可执行指令使处理器 501 执行上述基于深度学习的推荐方法对应的操作。输入/输出（I/O）接口 505 也连接至总线 504。通信部 512 可以集成设置，也可以设置为具有多个子模块（例如多个 IB 网卡），并在总线链接上。

以下部件连接至 I/O 接口 505：包括键盘、鼠标等的输入部分 506；包括诸如阴极射线管（CRT）、液晶显示器（LCD）等以及扬声器等的输出部分 507；包括硬盘等的存储部分 508；以及包括诸如 LAN 卡、调制解调器等网络接口卡的通信部分 509。通信部分 509 经由诸如因特网的网络执行通信处理。驱动器 510 也根据需要连接至 I/O 接口 505。可拆卸介质 511，诸如磁盘、光盘、磁光盘、半导体存储器等等，根据需要安装在驱动器 510 上，以便于从其上读出的计算机程序根据需要被安装入存储部分 508。

需要说明的，如图 5 所示的架构仅为一种可选实现方式，在实践过程中，可根据实际需要对上述图 5 的部件数量和类型进行选择、删减、增加或替换；在不同功能部件设置上，也可采用分离设置或集成设置等实现方式，例如 GPU 和 CPU 可分离设置或者可将 GPU 集

成在 CPU 上，通信部可分离设置，也可集成设置在 CPU 或 GPU 上，等等。这些可替换的实施方式均落入本申请公开的保护范围。

特别地，根据本公开的实施例，上文参考流程图描述的过程可以被实现为计算机软件程序。例如，本公开的实施例包括一种计算机程序产品，其包括有形地包含在机器可读介质上的计算机程序，计算机程序包含用于执行流程图所示的方法的程序代码，程序代码可包括对应执行本申请实施例提供的方法操作对应的指令，例如，分别获取目标用户的相关信息和目标物品的相关信息；分别利用集成模型中的至少两个子模型，基于目标用户的相关信息和目标物品的相关信息得到至少两个子模型对应的操作概率；基于至少两个子模型对应的操作概率得到目标用户操作目标物品的目标概率；基于目标概率为目标用户推荐目标物品。在这样的实施例中，该计算机程序可以通过通信部分 509 从网络上被下载和安装，和/或从可拆卸介质 511 被安装。在该计算机程序被中央处理单元（CPU）501 执行时，执行本申请的方法中限定的上述功能。

本说明书中各个实施例均采用递进的方式描述，每个实施例重点说明的都是与其它实施例的不同之处，各个实施例之间相同或相似的部分相互参见即可。对于系统实施例而言，由于其与方法实施例基本对应，所以描述的比较简单，相关之处参见方法实施例的部分说明即可。

可能以许多方式来实现本申请的方法和装置、设备。例如，可通过软件、硬件、固件或者软件、硬件、固件的任何组合来实现本申请的方法和装置、设备。用于方法的操作的上述顺序仅是为了进行说明，本申请的方法的操作不限于以上描述的顺序，除非以其它方式特别说明。此外，在一些实施例中，还可将本申请实施为记录在记录介质中的程序，这些程序包括用于实现根据本申请的方法的机器可读指令。因而，本申请还覆盖存储用于执行根据本申请的方法的程序的记录介质。

本申请的描述是为了示例和描述起见而给出的，而并不是无遗漏的或者将本申请限于所公开的形式。很多修改和变化对于本领域的普通技术人员而言是显然的。选择和描述实施例是为了更好说明本申请的原理和实际应用，并且使本领域的普通技术人员能够理解本申请从而设计适于特定用途的带有各种修改的各种实施例。