



(21) 申请号 202310862155.5

(22) 申请日 2023.07.13

(71) 申请人 京东科技信息技术有限公司

地址 100176 北京市大兴区北京经济技术
开发区科创十一街18号院2号楼6层
601

(72) 发明人 孔浩然 祝天刚 陈蒙

(74) 专利代理机构 北京律智知识产权代理有限
公司 11438

专利代理师 孙宝海

(51) Int. Cl.

G06Q 30/0202 (2023.01)

G06F 18/23 (2023.01)


权利要求书2页 说明书14页 附图4页

(54) 发明名称

活跃用户预测方法、装置、设备及存储介质

(57) 摘要

本公开提供了一种活跃用户预测方法、装置、设备及存储介质，涉及计算机数据处理技术领域。所述方法包括对各个用户在多个第一历史时段的浏览值进行时序聚类，得到目标用户簇；基于目标用户簇中各个用户在多个第二历史时段的行为数据，得到目标用户簇的时序特征值；基于预设活跃度预测模型对时序特征值进行处理，得到目标用户簇中各个用户在多个目标时段内的活跃度预测值，其中，目标时段为多个第二历史时段之后的时段；根据目标用户簇中各个用户在多个目标时段内的活跃度预测值，确定目标用户簇中的活跃用户。本公开通过时序聚类和时序预测，提升活跃用户预测的精确度和准确率。



1. 一种活跃用户预测方法,其特征在于,包括:

对各个用户在多个第一历史时段的浏览值进行时序聚类,得到目标用户簇;

基于所述目标用户簇中各个用户在多个第二历史时段的行为数据,得到所述目标用户簇的时序特征值;

基于预设活跃度预测模型对所述时序特征值进行处理,得到所述目标用户簇中各个用户在多个目标时段内的活跃度预测值,其中,所述目标时段为所述多个第二历史时段之后的时段;

根据所述目标用户簇中各个用户在多个目标时段内的活跃度预测值,确定所述目标用户簇中的活跃用户。

2. 根据权利要求1所述的方法,其特征在于,所述对各个用户在多个第一历史时段的浏览值进行时序聚类,得到目标用户簇,包括:

对各个用户在多个第一历史时段的浏览值进行时序聚类,得到所述各个用户的分簇编码,其中,一个分簇编码对应一个用户簇,一个用户簇内包括多个用户;

基于所述分簇编码和/或所述用户簇内用户数量进行过滤,得到所述目标用户簇。

3. 根据权利要求2所述的方法,其特征在于,所述对各个用户在多个第一历史时段的浏览值进行时序聚类,得到所述各个用户的分簇编码,包括:

根据预设浏览分桶关系,确定各个用户在各个所述第一历史时段的浏览值对应的分桶标识,其中,所述预设浏览分桶关系包括用户的浏览值与分桶标识之间的对应关系;

拼接各个用户在各个所述第一历史时段的浏览值对应的分桶标识,得到所述各个用户的分簇编码。

4. 根据权利要求3所述的方法,其特征在于,所述基于所述分簇编码和/或所述用户簇内用户数量进行过滤,得到所述目标用户簇,包括:

剔除目标分桶标识超过第一预设数量阈值的分簇编码对应的用户簇;和/或,剔除用户数量少于第二预设数量阈值的用户簇,得到所述目标用户簇。

5. 根据权利要求1所述的方法,其特征在于,所述基于所述目标用户簇中各个用户在多个第二历史时段的行为数据,得到所述目标用户簇的时序特征值,包括:

确定所述目标用户簇中各个用户在多个第二历史时段的行为数据的异常点;对所述异常点进行填补。

6. 根据权利要求1所述的方法,其特征在于,所述目标用户簇的时序特征值通过所述目标用户簇中各个用户在对应该第二历史时段的行为数据的平均值得到。

7. 根据权利要求1所述的方法,其特征在于,所述行为数据包括浏览值和扩展行为数据,其中,所述扩展行为数据包括搜索、加购、商品关注、付款、付款金额、首购距今天数、最近一次付款距今天数中的一项或多项。

8. 根据权利要求1所述的方法,其特征在于,所述预设活跃度预测模型包括自回归模型、移动平均模型、差分整合移动平均自回归模型或动态回归模型。

9. 根据权利要求1所述的方法,其特征在于,所述预设活跃度预测模型由目标用户簇中各个用户在多个第二历史时段的行为数据、以及所述各个用户在多个目标时段内的活跃度真实值训练得到,以模型准确率作为误差函数,其中,所述模型准确率为模型预测为活跃用户中真实活跃用户数量与模型预测为活跃用户数量的比值。

10. 根据权利要求1-9任一项所述的方法, 其特征在于, 所述根据所述目标用户簇中各个用户在多个目标时段内的活跃度预测值, 确定所述目标用户簇中的活跃用户, 包括:

将所述目标用户簇中各个用户在各个目标时段内的活跃度预测值归一化, 得到各个目标时段内的归一化预测值;

将所述各个目标时段内的归一化预测值进行融合, 得到所述目标用户簇中各个用户的目标活跃度预测值;

若所述各个用户的目标活跃度预测值大于或等于预设活跃度阈值, 则判定所述各个用户为活跃用户;

若所述各个用户的目标活跃度预测值小于所述预设活跃度阈值, 则判定所述各个用户为非活跃用户。

11. 一种活跃用户预测装置, 其特征在于, 包括:

时序聚类模块, 用于对各个用户在多个第一历史时段的浏览值进行时序聚类, 得到目标用户簇;

数据处理模块, 用于基于所述目标用户簇中各个用户在多个第二历史时段的行为数据, 得到所述目标用户簇的时序特征值;

活跃度预测模块, 用于基于预设活跃度预测模型对所述时序特征值进行处理, 得到所述目标用户簇中各个用户在多个目标时段内的活跃度预测值, 其中, 所述目标时段为所述多个第二历史时段之后的时段;

活跃用户确定模块, 用于根据所述目标用户簇中各个用户在多个目标时段内的活跃度预测值, 确定所述目标用户簇中的活跃用户。

12. 一种电子设备, 其特征在于, 包括: 处理器; 以及存储器, 用于存储所述处理器的可执行指令; 其中, 所述处理器配置为经由执行所述可执行指令来执行如权利要求1-10任一项所述的活跃用户预测方法。

13. 一种计算机可读存储介质, 其上存储有计算机程序, 其特征在于, 所述计算机程序被处理器执行时实现如权利要求1-10任一项所述的活跃用户预测方法。

活跃用户预测方法、装置、设备及存储介质

技术领域

[0001] 本公开涉及计算机数据处理技术领域,尤其涉及一种活跃用户预测方法、活跃用户预测装置、电子设备及计算机可读存储介质。

背景技术

[0002] 作为电商、网站、互联网应用等领域的运营情况的重要因素,活跃用户成为渠道推广的主要对象,利于提升下单转化率指标。

[0003] 在相关技术中,活跃用户通常采用线上监控技术和时序预测技术进行预测。然而,单个用户进行时序预测面临数据稀疏问题,造成预测结果精度低、适用范围差的问题。如何精确预测每一个用户在未来时刻的活跃度值成为亟待解决的技术问题。

[0004] 需要说明的是,在上述背景技术部分公开的信息仅用于加强对本公开的背景的理解,因此可以包括不构成对本领域普通技术人员已知的现有技术的信息。

发明内容

[0005] 本公开提供一种营销活跃用户预测、装置、设备及存储介质,至少在一定程度上克服相关技术中活跃用户预测方式存在预测结果精度低、适用范围差的问题。

[0006] 本公开的其他特性和优点将通过下面的详细描述变得显然,或部分地通过本公开的实践而习得。

[0007] 根据本公开的一个方面,提供一种活跃用户预测方法,包括:对各个用户在多个第一历史时段的浏览值进行时序聚类,得到目标用户簇;基于所述目标用户簇中各个用户在多个第二历史时段的行为数据,得到所述目标用户簇的时序特征值;基于预设活跃度预测模型对所述时序特征值进行处理,得到所述目标用户簇中各个用户在多个目标时段内的活跃度预测值,其中,所述目标时段为所述多个第二历史时段之后的时段;根据所述目标用户簇中各个用户在多个目标时段内的活跃度预测值,确定所述目标用户簇中的活跃用户。

[0008] 在本公开的一个实施例中,所述对各个用户在多个第一历史时段的浏览值进行时序聚类,得到目标用户簇,包括:对各个用户在多个第一历史时段的浏览值进行时序聚类,得到所述各个用户的分簇编码,其中,一个分簇编码对应一个用户簇,一个用户簇内包括多个用户;基于所述分簇编码和/或所述用户簇内用户数量进行过滤,得到所述目标用户簇。

[0009] 在本公开的一个实施例中,所述对各个用户在多个第一历史时段的浏览值进行时序聚类,得到所述各个用户的分簇编码,包括:根据预设浏览分桶关系,确定各个用户在各个所述第一历史时段的浏览值对应的分桶标识,其中,所述预设浏览分桶关系包括用户的浏览值与分桶标识之间的对应关系;拼接各个用户在各个所述第一历史时段的浏览值对应的分桶标识,得到所述各个用户的分簇编码。

[0010] 在本公开的一个实施例中,所述基于所述分簇编码和/或所述用户簇内用户数量进行过滤,得到所述目标用户簇,包括:剔除目标分桶标识超过第一预设数量阈值的分簇编码对应的用户簇;和/或,剔除用户数量少于第二预设数量阈值的用户簇,得到所述目标用

户簇。

[0011] 在本公开的一个实施例中,所述基于所述目标用户簇中各个用户在多个第二历史时段的行为数据,得到所述目标用户簇的时序特征值,包括:确定所述目标用户簇中各个用户在多个第二历史时段的行为数据的异常点;对所述异常点进行填补。

[0012] 在本公开的一个实施例中,所述目标用户簇的时序特征值通过所述目标用户簇中各个用户在对应第二历史时段的行为数据的平均值得到。

[0013] 在本公开的一个实施例中,所述行为数据包括浏览值和扩展行为数据,其中,所述扩展行为数据包括搜索、加购、商品关注、付款、付款金额、首购距今天数、最近一次付款距今天数中的一项或多项。

[0014] 在本公开的一个实施例中,所述预设活跃度预测模型包括自回归模型、移动平均模型、差分整合移动平均自回归模型或动态回归模型。

[0015] 在本公开的一个实施例中,所述预设活跃度预测模型由目标用户簇中各个用户在多个第二历史时段的行为数据、以及所述各个用户在多个目标时段内的活跃度真实值训练得到,以模型准确率作为误差函数,其中,所述模型准确率为模型预测为活跃用户中真实活跃用户数量与模型预测为活跃用户数量的比值。

[0016] 在本公开的一个实施例中,所述根据所述目标用户簇中各个用户在多个目标时段内的活跃度预测值,确定所述目标用户簇中的活跃用户,包括:将所述目标用户簇中各个用户在各个目标时段内的活跃度预测值归一化,得到各个目标时段内的归一化预测值;将所述各个目标时段内的归一化预测值进行融合,得到所述目标用户簇中各个用户的目标活跃度预测值;若所述各个用户的目标活跃度预测值大于或等于预设活跃度阈值,则判定所述各个用户为活跃用户;若所述各个用户的目标活跃度预测值小于所述预设活跃度阈值,则判定所述各个用户为非活跃用户。

[0017] 在本公开的另一个方面,还提供了一种活跃用户预测装置,包括:时序聚类模块,用于对各个用户在多个第一历史时段的浏览值进行时序聚类,得到目标用户簇;数据处理模块,用于基于所述目标用户簇中各个用户在多个第二历史时段的行为数据,得到所述目标用户簇的时序特征值;活跃度预测模块,用于基于预设活跃度预测模型对所述时序特征值进行处理,得到所述目标用户簇中各个用户在多个目标时段内的活跃度预测值,其中,所述目标时段为所述多个第二历史时段之后的时段;活跃用户确定模块,用于根据所述目标用户簇中各个用户在多个目标时段内的活跃度预测值,确定所述目标用户簇中的活跃用户。

[0018] 根据本公开的另一个方面,提供一种电子设备,包括:处理器;以及存储器,用于存储所述处理器的可执行指令;其中,所述处理器配置为经由执行所述可执行指令来执行上述的活跃用户预测方法。

[0019] 根据本公开的另一个方面,提供了一种计算机可读存储介质,其上存储有计算机程序,所述计算机程序被处理器执行时实现上述的活跃用户预测方法。

[0020] 根据本公开的又一个方面,提供一种计算机程序产品,所述计算机程序产品包括计算机程序或计算机指令,所述计算机程序或所述计算机指令由处理器加载并执行,以使计算机实现上述的活跃用户预测方法。

[0021] 在本公开实施例中,对各个用户在多个第一历史时段的浏览值进行时序聚类,得

到目标用户簇;基于目标用户簇中各个用户在多个第二历史时段的行为数据,得到目标用户簇的时序特征值;基于预设活跃度预测模型对时序特征值进行处理,得到目标用户簇中各个用户在多个目标时段内的活跃度预测值;根据目标用户簇中各个用户在多个目标时段内的活跃度预测值,确定目标用户簇中的活跃用户,本公开通过时序聚类将各个用户按照浏览值和第一历史时段划分至不同的用户簇,得到目标用户簇,使一个目标用户簇内的用户具有相同或相似的分布,有效解决数据稀疏问题,从而提升预测的精确度,通过时序预测方法,可以针对电商领域中用户稀疏的历史行为数据构建活跃度预测模型,能够覆盖全体用户,用户活跃度准确率达到80%以上。

[0022] 应当理解的是,以上的一般描述和后文的细节描述仅是示例性和解释性的,并不能限制本公开。

附图说明

[0023] 此处的附图被并入说明书中并构成本说明书的一部分,示出了符合本公开的实施例,并与说明书一起用于解释本公开的原理。显而易见地,下面描述中的附图仅仅是本公开的一些实施例,对于本领域普通技术人员来讲,在不付出创造性劳动的前提下,还可以根据这些附图获得其他的附图。

[0024] 图1示出本公开实施例提供的活跃用户预测系统架构图;

[0025] 图2示出本公开实施例提供的一种活跃用户预测方法流程图;

[0026] 图3示出本公开实施例提供的目标用户簇确定方法流程图;

[0027] 图4示出本公开实施例提供的目标用户簇的时序特征值确定方法流程;

[0028] 图5示出本公开实施例提供的时序异常点判定方法流程图;

[0029] 图6示出本公开实施例提供的根据活跃度预测值确定用户状态方法流程图;

[0030] 图7示出本公开实施例提供的一种活跃用户预测装置的结构示意图;

[0031] 图8示出本公开实施例提供的电子设备的结构框图。

具体实施方式

[0032] 现在将参考附图更全面地描述示例实施方式。然而,示例实施方式能够以多种形式实施,且不应被理解为限于在此阐述的范例;相反,提供这些实施方式使得本公开将更加全面和完整,并将示例实施方式的构思全面地传达给本领域的技术人员。所描述的特征、结构或特性可以以任何合适的方式结合在一个或更多实施方式中。

[0033] 此外,附图仅为本公开的示意性图解,并非一定是按比例绘制。图中相同的附图标记表示相同或类似的部分,因而将省略对它们的重复描述。附图中所示的一些方框图是功能实体,不一定必须与物理或逻辑上独立的实体相对应。可以采用软件形式来实现这些功能实体,或在一个或多个硬件模块或集成电路中实现这些功能实体,或在不同网络和/或处理器装置和/或微控制器装置中实现这些功能实体。

[0034] 图1示出了可以应用本公开实施例的活跃用户预测方法、或活跃用户预测装置的示例性系统架构100。

[0035] 如图1所示,系统架构100可以包括终端设备110,网络120和服务器130。

[0036] 网络120用以在终端设备110和服务器130之间提供通信链路的介质,可以是有线

网络,也可以是无线网络。

[0037] 用户可以使用终端设备110通过网络120与服务器130交互,以接收或发送消息。

[0038] 终端设备110可以是具有显示屏且支持网页浏览的各种电子设备,包括但不限于智能手机、平板电脑、显示屏和台式电脑等。

[0039] 终端设备110上可以安装的应用程序的客户端是相同的,或基于不同操作系统的同一类型应用程序的客户端。基于终端平台的不同,该应用程序的客户端的具体形态也可以不同,比如,该应用程序客户端可以是手机客户端、PC客户端等。

[0040] 示例性的,终端设备110安装有各种通讯客户端应用,例如购物类应用、网页浏览器应用、搜索类应用、即时通讯工具、邮箱客户端、社交平台软件等,通过通讯客户端应用可以采集用户在历史时段的浏览值或其他行为数据,根据采集到的浏览值进行时序聚类,得到目标用户簇,进而根据目标用户簇在历史时段的行为数据确定目标用户簇中各个用户在目标时段的活跃度预测值,以确定活跃用户。

[0041] 服务器130可以是提供各种服务的服务器,例如对用户利用终端设备110所进行操作的装置提供支持的后台管理服务器。后台管理服务器可以对接收到的请求等数据(例如用户的浏览值或其他行为数据等)进行分析等处理,得到处理结果(例如活跃度预测值、活跃用户等)。

[0042] 可选地,服务器130可以是独立的物理服务器,也可以是多个物理服务器构成的服务器集群或者分布式系统,还可以是提供云服务、云数据库、云计算、云函数、云存储、网络服务、云通信、中间件服务、域名服务、安全服务、CDN(Content Delivery Network,内容分发网络)、以及大数据和人工智能平台等基础云计算服务的云服务器。

[0043] 本领域技术人员可以知晓,图1中的终端设备、网络和服务器的数量仅仅是示意性的,根据实际需要,可以具有任意数目的终端设备、网络和服务器的。本公开实施例对此不作限定。

[0044] 作为电商、网站、互联网应用等领域的运营情况的重要分析数据,日活跃用户数能够为渠道推广、成本预估提供一些数据支持和帮助。针对活跃用户投放广告,能够带来转化率提升,而投放时机的选择,取决于用户活跃度,用户的活跃行为以浏览为主。

[0045] 在相关技术中,活跃用户预测方法主要分为两种:线上监测技术、时序预测技术。其中,线上监测技术通过监控用户数据,实时捕捉线上活跃用户是否产生浏览记录,从而对实时活跃用户投放广告。时序预测技术根据用户过去一段时间的时序数据,预测下一时刻或者未来多个时刻的活跃度值。

[0046] 然而,活跃用户线上监测技术,仅能够获取到部分实时活跃用户,无法覆盖全体平台的用户,造成效率低下的问题;时序预测技术旨在通过用户过去一段时间的行为数据,预测下一时刻或未来多个时刻的活跃度值,事实上,绝大多数平台的用户行为数据稀疏,导致历史行为序列不具有时序特性,从而降低时序预测技术的预测结果精确度。

[0047] 为了解决相关技术中活跃用户预测方式存在预测结果精度低、适用范围差的技术问题,本公开提出了一种基于时序聚类和时序预测的活跃用户预测方法。基于用户历史时序数据,通过时序聚类生成用户簇,根据用户簇的历史时序数据分布,填补时序数据异常值;针对平台用户群体(例如电商平台的用户群体),将其历史时序数据作为输入,使用时序预测方法,输出用户簇中用户未来多个时刻的活跃度值。

[0048] 本公开实施例提供一种活跃用户预测方法,通过对各个用户在多个第一历史时段的浏览值进行时序聚类,得到目标用户簇;基于目标用户簇中各个用户在多个第二历史时段的行为数据,得到目标用户簇的时序特征值;基于预设活跃度预测模型对时序特征值进行处理,得到目标用户簇中各个用户在多个目标时段内的活跃度预测值;根据目标用户簇中各个用户在多个目标时段内的活跃度预测值,确定目标用户簇中的活跃用户,本公开通过时序聚类将各个用户按照浏览值和第一历史时段划分至不同的用户簇,得到目标用户簇,使一个目标用户簇内的用户具有相同或相似的分布,有效解决数据稀疏问题,从而提升预测的精确度,通过时序预测方法,可以针对电商领域中用户稀疏的历史行为数据构建活跃度预测模型,能够覆盖全体用户,用户活跃度准确率达到80%以上。

[0049] 需要指出的是,在不冲突的情况下,本发明的实施例以及实施例中的技术特征可以相互结合。

[0050] 下面结合附图及实施例对本示例实施方式进行详细说明。

[0051] 首先,本公开实施例中提供了一种活跃用户预测方法,该方法可以由任意具备计算处理能力的系统执行。在一些实施例中,本公开实施例中提供的活跃用户预测方法,可以由服务器执行;在另一些实施例中,本公开实施例提供活跃用户预测方法可以由终端设备和服务器通过交互的方式来实现。

[0052] 图2示出本公开实施例中提供一种活跃用户预测方法流程图,如图2所示,本公开实施例中提供的活跃用户预测方法,包括如下步骤:

[0053] S202、对各个用户在多个第一历史时段的浏览值进行时序聚类,得到目标用户簇。

[0054] 在S202中,上述的用户为通过终端设备在多个第一历史时段中登录平台的用户,多个第一历史时段相对当前时段而言,多个第一历史时段为当前时段之前的时段。

[0055] 示例性的,多个第一历史时段可以选择当前时段过去7天的时段,例如,可以选择用户在过去7天的浏览值。

[0056] 上述的对各个用户在多个第一历史时段的浏览值进行时序聚类,可以针对不同用户在各个第一历史时段的浏览值进行时序聚类,将多个浏览值具有相同或相似分布的用户划分到相同用户簇,从而为时序预测提供数据支持。

[0057] 上述目标用户簇可以为时序聚类得到的全部用户簇中的一个用户簇,若通过时序聚类得到的用户簇为两个或两个以上,则可以分别对各个用户簇进行时序预测。

[0058] S204、基于目标用户簇中各个用户在多个第二历史时段的行为数据,得到目标用户簇的时序特征值。

[0059] 需要说明的是,目标用户簇中各个用户在多个第二历史时段的行为数据可以包括浏览值和扩展行为数据,其中,扩展行为数据包括搜索、加购、商品关注、付款、付款金额、首购距今天数、最近一次付款距今天数中的一项或多项。通过扩展行为数据能够补充其他特征的时序归类对浏览值的影响,从而提升预测的精确度。

[0060] 多个第二历史时段可以为目标用户簇中各个用户在过去50天的行为数据,每天的行为数据作为一个第二历史时段的行为数据。

[0061] 目标用户簇的时序特征值可以为对多个历史时段的行为数据进行处理后得到的,上述处理可以包括筛选异常值、填补异常值等。

[0062] S206、基于预设活跃度预测模型对时序特征值进行处理,得到目标用户簇中各个

用户在多个目标时段内的活跃度预测值,其中,目标时段为多个第二历史时段之后的时段。

[0063] 需要说明的是,多个目标时段可以为未来特定天数的时段,例如,可以将未来4天的活跃度作为多个目标时段内的活跃度预测值。

[0064] 示例性的,基于预设活跃度预测模型,以目标用户簇中用户在过去50天的行为数据得到的时序特征值作为输入量,以目标用户簇中各个用户未来4天的活跃度预测值作为输出量,进行时序预测。

[0065] 在实际应用时,由于模型训练时间较长,因此,当天预测结果无法有效使用,舍弃当天的活跃度预测值。

[0066] 在S206中,预设活跃度预测模型为训练完成的活跃度预测模型。在模型训练时,预设活跃度预测模型由目标用户簇中各个用户在多个第二历史时段的行为数据、以及各个用户在多个目标时段内的活跃度真实值训练得到,以模型准确率作为误差函数,其中,模型准确率为模型预测为活跃用户中真实活跃用户数量与模型预测为活跃用户数量的比值。

[0067] 需要说明的是,上述活跃度预测模型的模型训练和模型预测在同一天完成,使用时,由于用户簇的数据持续变化,故每天训练一次活跃度预测模型,同时进行活跃用户预测,为商家提供活跃用户池(或范围),例如线上投放广告时,可以从上述活跃用户池中选择用户进行投放,该方式与选择全量用户相比,活跃准确率由25%提升至80%。

[0068] S208、根据目标用户簇中各个用户在多个目标时段内的活跃度预测值,确定目标用户簇中的活跃用户。

[0069] 在一个实施例中,通过比较活跃度预测值与预设条件之间的关系,确定目标用户簇中的活跃用户。预设条件可以根据实际情况而定,例如可以取预设活跃度阈值作为衡量标准。

[0070] 在本公开实施例中,对各个用户在多个第一历史时段的浏览值进行时序聚类,得到目标用户簇;基于目标用户簇中各个用户在多个第二历史时段的行为数据,得到目标用户簇的时序特征值;基于预设活跃度预测模型对时序特征值进行处理,得到目标用户簇中各个用户在多个目标时段内的活跃度预测值;根据目标用户簇中各个用户在多个目标时段内的活跃度预测值,确定目标用户簇中的活跃用户,本公开通过时序聚类将各个用户按照浏览值和第一历史时段划分至不同的用户簇,得到目标用户簇,使一个目标用户簇内的用户具有相同或相似的分布,有效解决数据稀疏问题,从而提升预测的精确度,通过时序预测方法,可以针对电商领域中用户稀疏的历史行为数据构建活跃度预测模型,能够覆盖全体用户,用户活跃度准确率达到80%以上。

[0071] 图3示出了本公开实施例提供的目标用户簇确定方法流程图。在图2实施例的基础上,进一步对S202进行限定,以确定目标用户簇。如图3所示,在本公开一个实施例中,上述的S202对各个用户在多个第一历史时段的浏览值进行时序聚类,得到目标用户簇,包括:

[0072] S302、对各个用户在多个第一历史时段的浏览值进行时序聚类,得到各个用户的分簇编码,其中,一个分簇编码对应一个用户簇,一个用户簇内包括多个用户。

[0073] 需要说明的是,上述的分簇编码可以作为一个用户簇的标识,分簇编码可以采用数字、字母、符号等表示。

[0074] 在对各个用户在多个第一历史时段的浏览值进行时序聚类时,可以按照用户的浏览值所处的浏览值区间进行划分,每个浏览值区间的长度可以根据实际情况而定。

[0075] S304、基于分簇编码和/或用户簇内用户数量进行过滤,得到目标用户簇。

[0076] 考虑到不同用户簇内用户数量、一个用户簇内用户的浏览值不同,可以从时序聚类得到的用户簇中过滤掉部分用户簇,以保证用户历史数据具有一定时序特点,从而使时序预测的结果更准确。

[0077] 在一个实施例中,上述S302对各个用户在多个第一历史时段的浏览值进行时序聚类,得到各个用户的分簇编码,包括:

[0078] 根据预设浏览分桶关系,确定各个用户在各个第一历史时段的浏览值对应的分桶标识,其中,预设浏览分桶关系包括用户的浏览值与分桶标识之间的对应关系;

[0079] 拼接各个用户在各个第一历史时段的浏览值对应的分桶标识,得到各个用户的分簇编码。

[0080] 需要说明的是,预设浏览分桶关系可以预先配置于服务器内,浏览分桶关系用于表征用户的浏览值与分桶标识之间的对应关系,其中,分桶标识可以采用数字、字母、符号等形式表示。

[0081] 预设浏览分桶关系可以采用浏览分桶关系表、浏览分桶关系曲线等形式进行标识,本公开不做具体限定。表1示出浏览分桶关系表的一种形式。

[0082] 表1浏览分桶关系表

[0083]	类型	分桶 1	分桶 2	分桶 3	分桶 4	分桶 5	分桶 6	分桶 7	分桶 8
	浏览分桶区间	0	1-2	3-5	6-8	9-11	12-14	15-20	>20

[0084] 当获取到各个用户在多个第一历史时段的浏览值时,通过查找预设浏览分桶关系(例如对应关系表等),即可确定各个第一历史时段的浏览值对应的分桶标识,将查找得到的各个分桶标识按照时段先后顺序进行拼接,得到用户的分簇编码,本公开实施例通过将用于在各个第一历史时段的浏览值匹配对应的分桶标识,从而对用户在多个第一历史时段的浏览值进行数值离散化。

[0085] 示例性的,以浏览值作为活跃度,对各个用户过去7天的浏览值进行数值离散化,查找表1,确定用户过去7天的浏览值对应的分桶标识,随后将7天的分桶标识进行拼接,得到用户的分簇编码,当分桶标识采用数据表示时,分簇编码可以在1111111至8888888之间取值,例如1112111。

[0086] 在一个实施例中,上述S304基于分簇编码和/或用户簇内用户数量进行过滤,得到目标用户簇,包括:剔除目标分桶标识超过第一预设数量阈值的分簇编码对应的用户簇;和/或,剔除用户数量少于第二预设数量阈值的用户簇,得到目标用户簇。

[0087] 需要说明的是,目标分桶标识可以为分桶1即浏览值为0对应的分桶标识,也可以由用户指定,不做具体限定。

[0088] 上述的第一预设数量阈值可以根据第一历史时段的数量而定,例如,以用户过去7天的浏览值作为对象,第一预设数量阈值可以选取6、7等。

[0089] 示例性的,在进行时序聚类得到全部用户簇之后,从上述用户簇中剔除目标分桶标识超过第一预设数量阈值的分簇编码对应的用户簇,如从用户簇中剔除含有6位或7位分

桶标识为1的分簇编码对应的用户簇,例如1111111、1112111、1111112等,从而保证用户的行为数据具有一定时序特点,提升模型预测的精确度。

[0090] 需要说明的是,对于从用户簇中剔除含有6位分桶标识为1的分簇编码对应的用户簇,即用户过去7天中的6天没有浏览,表明用户过去7天的第一历史时段内不具有时序规律,也可以看出,最近7天该用户不够“活跃”,故上述用户簇的用户数据对预测的收益不是很大,因而舍弃。

[0091] 除此之外,为了保证用户簇的规模,防止较少用户数量的用户簇内存在异常数值,使得最终的预测结果不够准确,故剔除掉用户簇内用户数量较少的聚类,第二预设数量阈值可以取10等,根据实际情况而定。

[0092] 例如,1个用户簇内包括5个用户,其中4个用户的浏览值均为0,剩余1个用户的浏览值为1000,此类用户簇的平均结果无法代表全体用户,故剔除此用户簇。

[0093] 图4示出本公开实施例提供的目标用户簇的时序特征值确定方法流程图。在一个实施例中,上述S206基于目标用户簇中各个用户在多个第二历史时段的行为数据,得到目标用户簇的时序特征值,包括:

[0094] S402、确定目标用户簇中各个用户在多个第二历史时段的行为数据的异常点;对异常点进行填补。

[0095] 在一个实施例中,基于离群点检测算法对目标用户簇中各个用户在多个第二历史时段的行为数据进行异常监测,并通过KNN最近邻算法等进行时序数据异常点处理。其中,离群点检测算法包括EllipticEnvelope算法、IsolationForest算法、LocalOutlierFactor算法等。

[0096] 示例性的,如图5所示,EllipticEnvelope算法为各个用户在多个第二历史时段的行为数据圈定一个高斯分布椭圆(Ellipse),位于椭圆内部的点(Normal data points)被视作正常点,位于椭圆外部的点(Outliers)被视作异常点。

[0097] 多个第二历史时段的行为数据按照时间先后顺序构成时序数据,针对时序数据上的异常点,采用KNN最近邻算法,利用异常点最近的5个时序点取平均值对异常点填补。

[0098] 需要说明的是,除了采用KNN最近邻算法填补异常点之外,还可以采用回归法、均值法等方式填补异常值。

[0099] 本公开实施例通过确定并填补各个用户在多个第二历史时段的行为数据的异常点,从而保证各个行为数据的准确性,降低数据波动对时序预测结果的影响。

[0100] 继续参考图4,在本公开的另一个实施例中,目标用户簇的时序特征值通过目标用户簇中各个用户在对应第二历史时段的行为数据的平均值得到。

[0101] 示例性的,目标用户簇中包含20个用户,每个用户的行为数据包括过去50天的浏览值和扩展行为数据,计算过去第1天20个用户的浏览值的平均值,即为该目标用户簇第1天浏览值列对应的时序特征值,直至计算过去第50天20个用户的浏览值的平均值,作为该目标用户簇第50天浏览值列对应的时序特征值。扩展行为数据对应的时序特征值的计算方式与浏览值的计算方式一致,不再赘述。

[0102] 在本公开实施例中,由于在同一目标用户簇中各个用户的行为数据具有相同或相似分布,将各个用户在对应第二历史时段的行为数据的平均值作为目标用户簇的时序特征值,从而有效克服单一用户数据稀疏造成的影响,提升时序预测的精确度,降低模型预测时

间,提升预测效率。

[0103] 在一个实施例中,上述的预设活跃度预测模型可以包括自回归模型(Autoregressive Model,AR模型)、移动平均模型(Moving Average Model,MA模型)、差分整合移动平均自回归模型(Autoregressive Integrated Moving Average model,ARIMA模型)或ARIMAX模型。

[0104] 自回归模型是统一上一种处理时间序列的方法,用于表征当前值与历史值之间的关系,基于自身历史数据来对自身进行预测,该模型的前提要求为数据具有平稳性、自相关性,采用如下公式进行表示:

$$[0105] \quad y_t = \mu + \sum_{i=1}^p w_i y_{t-i} + \varepsilon_t \quad (\text{公式一})$$

[0106] 其中, y_t 为当前值(或称活跃度预测值); y_{t-i} 为 $t-i$ 时段的浏览值; p 为阶数或称第二历史时段的数量; μ 为常数项; w_i 为自相关系数, ε_t 为误差值。

[0107] 移动平均模型为自回归模型误差项的累加,以消除时序预测中的随机波动,采用如下公式进行表示:

$$[0108] \quad y_t = \mu + \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \varepsilon_t \quad (\text{公式二})$$

[0109] 其中, y_t 为当前值; μ 为常数项; q 是阶数; θ_i 是自相关系数, ε_t 是误差值。

[0110] 差分整合移动平均自回归模型ARIMA,表示自回归模型和移动平均模型的组合,输入数据需要提前进行差分处理,预测结果也要通过差分还原求得,采用如下公式进行表示:

$$[0111] \quad \Delta^D y_t = \mu + \sum_{i=1}^p w_i \Delta^D y_{t-i} + \varepsilon_t + \sum_{j=1}^q \theta_j \varepsilon_{t-j} \quad (\text{公式三})$$

[0112] 其中, $\Delta^D y_t$ 为当前值的差分项, $\Delta^D y_{t-i}$ 表示历史值的差分项, ε_t 是误差值, μ 为常数项, p 、 q 是阶数, w_i 、 θ_j 为自相关系数。

[0113] ARIMAX模型是ARIMA模型的扩展模型,又称为带有干预序列的ARIMA模型或者动态回归模型。在ARIMA模型基础上,可以接受额外变量输入,该模型要求目标序列(预测浏览值或称活跃度预测值)和输入变量序列(时序特征值,或者多个第二历史时段的行为数据)均平稳,因而需要提前进行差分处理,预测结果也要通过差分还原求得,目标序列与输入序列之间的回归公式如下:

$$[0114] \quad \Delta^D y_t = \sum_{i=1}^p w_i \Delta^D y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \sum_{m=1}^M \beta_m X_{m,t} + \varepsilon_t \quad (\text{公式四})$$

[0115] 其中, ε_t 是误差值, $\varepsilon_t \sim N(0, \sigma^2)$ 的正态分布, y_t 为当前值, $\Delta^D y_t$ 为当前值的差分项,因为ARIMAX接受平稳的输入序列, $\Delta^D y_{t-i}$ 表示历史值的差分项, w_i 为自相关系数, p 为自回归模型的系数,表示多长历史时序数据作为输入,举例说明, $p=2$ 表示当前值的上一时刻和上上时刻历史值作为输入。 ε_{t-j} 表示平稳的历史残差序列, θ_j 表示自回归系数; q 表示移

动平均模型的阶数, $X_{m,t}$ 表示当前时刻其他特征输入, 举例说明, 本研究中, $X_{m,t}$ 表示除了浏览以外的加购、付款等特征。 M 表示其他特征个数, β_m 为权重系数。

[0116] 示例性的, ARIMAX 模型可以表征用户在多个第二历史时段的行为数据 (浏览值和扩展行为数据, 扩展行为数据包括但不限于加购、付款等) 得到的时序特征值与目标用户簇内各个用户在多个目标时段内的活跃度之间的对应关系。例如, 一共 3 类行为数据, 分别为浏览、加购、付款, 过去 50 天的浏览时序数据、过去 50 天的加购时序数据、过去 50 天的付款时序数据作为时序特征值, 预测目标是未来多个目标时段的活跃度预测值, 在本公开中, 预测目标是未来 4 天的活跃度预测值。

[0117] 需要说明的是, 对于 AR 模型、MA 模型、ARIMA 模型只需将扩展行为数据项的回归系数设置为 0 即可。

[0118] 本公开通过采用多种活跃度预测模型, 确定多个第二历史时段的行为数据与多个目标时段的活跃度预测值之间的关系, 除了学习历史浏览值的时序规律与下一时刻浏览值之间的关系之外, 还补充其他特征 (例如加购、付款等) 的时序规律对浏览值的影响, 从而提升模型预测的精确度。

[0119] 图 6 示出本公开实施例提供的根据活跃度预测值确定用户状态方法流程图。如图 6 所示, 在本公开的一个实施例中, 上述 S208 根据目标用户簇中各个用户在多个目标时段内的活跃度预测值, 确定目标用户簇中的活跃用户, 包括:

[0120] S602、将目标用户簇中各个用户在各个目标时段内的活跃度预测值归一化, 得到各个目标时段内的归一化预测值;

[0121] S604、将各个目标时段内的归一化预测值进行融合, 得到目标用户簇中各个用户的目标活跃度预测值;

[0122] S606、判断各个用户的目标活跃度预测值是否大于或等于预设活跃度阈值, 若大于或等于, 则执行 S608, 若小于, 则执行 S610;

[0123] S608、判定各个用户为活跃用户;

[0124] S610、判定各个用户为非活跃用户。

[0125] 在一个实施例中, 将目标用户簇中各个用户在各个目标时段内的活跃度预测值归一化至 0~1 之间, 采用如下公式归一化:

$$[0126] \quad y = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (\text{公式五})$$

[0127] 其中, $x_{\max}$, $x_{\min}$ 为预测的活跃度最大值和活跃度最小值, x_i 为当前活跃度值。

[0128] 示例性的, 在实际应用时, 模型当天训练时间较长, 因此当天预测结果无法有效使用, 故舍弃当前活跃度预测值, 将预测得到的 4 天 (多个目标时段) 中未来 3 天 (除当天之外) 的活跃度预测值进行融合, 得到目标用户簇中各个用户未来 3 天范围的活跃度预测值。活跃度预测值的融合公式如下:

$$[0129] \quad \begin{cases} y = y_{\max} + 0.02 \times y_{\text{median}} + 0.01 \times y_{\min}, & y_{\max} \geq 0.1; \\ y = y_{\max} - 0.02 \times y_{\text{median}} - 0.01 \times y_{\min}, & y_{\max} < 0.1; \end{cases} \quad (\text{公式六})$$

[0130] 其中, $y_{\max}$, y_{median} , $y_{\min}$ 分别表示模型预测得到的未来 3 天最大活跃度预测值, 中间活跃度预测值, 最小活跃度预测值, 通过以未来 3 天内活跃度预测值最大的 1 天为准, 其余 2 天配置相应权重, 从而提升预测结果的准确性。

[0131] 需要说明的是,上述的预设活跃度阈值可以取0.1,也可以根据实际情况而定,本公开不做具体限定。

[0132] 当目标用户簇中各个用户的目标活跃度预测值大于或等于0.1时,判定目标用户簇中各个用户为活跃用户,基于目标用户簇与簇内用户之间的映射,即可得到用户相关信息;当目标用户簇中各个用户的目标活跃度预测值小于0.1时,判定目标用户簇中各个用户为非活跃用户。

[0133] 对于活跃度预测模型的评估指标采用准确率进行评价,准确率为模型预测为活跃用户中真实活跃用户的占比。需要说明的是,任一用户只要在任一目标时段满足活跃条件,可视为活跃用户,例如,任一用户只要在未来3天内的任一天满足活跃条件(浏览值或活跃值 ≥ 1),可视为活跃用户。

[0134] 准确率Precision计算公式为:

$$[0135] \quad P = \frac{\{\text{预测为活跃用户中, 真实活跃用户数量(活跃值} \geq 1)\}}{\{\text{模型预测为活跃用户数量(活跃归一化分数} \geq 0.1)\}} \quad (\text{公式七})$$

[0136] 在模型训练时,可以将活跃度预测模型的准确率达到预设准确率阈值作为模型训练停止条件,预设准确率阈值可以为75%、80%等,根据实际需求而定。

[0137] 取4天前的活跃用户预测结果,依照已经过去4天中的后3天真实值,线上监控模型性能,评估指标依旧选用Precision。

[0138] 基于同一发明构思,本公开实施例中还提供了一种活跃用户预测装置,如下面的实施例。由于该装置实施例解决问题的原理与上述方法实施例相似,因此该装置实施例的实施可以参见上述方法实施例的实施,重复之处不再赘述。

[0139] 图7示出本公开实施例提供的一种活跃用户预测装置示意图。如图7所示,本实施例的活跃用户预测装置,包括时序聚类模块710、数据处理模块720、活跃度预测模块730和活跃用户确定模块740。

[0140] 时序聚类模块710,用于对各个用户在多个第一历史时段的浏览值进行时序聚类,得到目标用户簇;

[0141] 数据处理模块720,用于基于目标用户簇中各个用户在多个第二历史时段的行为数据,得到目标用户簇的时序特征值;

[0142] 活跃度预测模块730,用于基于预设活跃度预测模型对时序特征值进行处理,得到目标用户簇中各个用户在多个目标时段内的活跃度预测值,其中,目标时段为多个第二历史时段之后的时段;

[0143] 活跃用户确定模块740,用于根据目标用户簇中各个用户在多个目标时段内的活跃度预测值,确定目标用户簇中的活跃用户。

[0144] 在一个实施例中,时序聚类模块710,用于对各个用户在多个第一历史时段的浏览值进行时序聚类,得到各个用户的分簇编码,其中,一个分簇编码对应一个用户簇,一个用户簇内包括多个用户;基于分簇编码和/或用户簇内用户数量进行过滤,得到目标用户簇。

[0145] 在一个实施例中,时序聚类模块710,用于根据预设浏览分桶关系,确定各个用户在各个第一历史时段的浏览值对应的分桶标识,其中,预设浏览分桶关系包括用户的浏览值与分桶标识之间的对应关系;拼接各个用户在各个第一历史时段的浏览值对应的分桶标

识,得到各个用户的分簇编码。

[0146] 在一个实施例中,时序聚类模块710,还用于剔除目标分桶标识超过第一预设数量阈值的分簇编码对应的用户簇;和/或,剔除用户数量少于第二预设数量阈值的用户簇,得到目标用户簇。

[0147] 在一个实施例中,数据处理模块720,用于确定目标用户簇中各个用户在多个第二历史时段的行为数据的异常点;对异常点进行填补。

[0148] 在一个实施例中,数据处理模块720,还用于通过目标用户簇中各个用户在对应第二历史时段的行为数据的平均值得到目标用户簇的时序特征值。

[0149] 需要说明的是,行为数据包括浏览值和扩展行为数据,其中,扩展行为数据包括搜索、加购、商品关注、付款、付款金额、首购距今天数、最近一次付款距今天数中的一项或多项。

[0150] 需要说明的是,预设活跃度预测模型包括自回归模型、移动平均模型、差分整合移动平均自回归模型或动态回归模型。

[0151] 在一个实施例中,活跃度预测模块730,用于训练活跃度预测模型,预设活跃度预测模型由目标用户簇中各个用户在多个第二历史时段的行为数据、以及各个用户在多个目标时段内的活跃度真实值训练得到,以模型准确率作为误差函数,其中,模型准确率为模型预测为活跃用户中真实活跃用户数量与模型预测为活跃用户数量的比值。

[0152] 在一个实施例中,活跃用户确定模块740,用于将目标用户簇中各个用户在各个目标时段内的活跃度预测值归一化,得到各个目标时段内的归一化预测值;将各个目标时段内的归一化预测值进行融合,得到目标用户簇中各个用户的目标活跃度预测值;若各个用户的目标活跃度预测值大于或等于预设活跃度阈值,则判定各个用户为活跃用户;若各个用户的目标活跃度预测值小于预设活跃度阈值,则判定各个用户为非活跃用户。

[0153] 在本公开实施例中,对各个用户在多个第一历史时段的浏览值进行时序聚类,得到目标用户簇;基于目标用户簇中各个用户在多个第二历史时段的行为数据,得到目标用户簇的时序特征值;基于预设活跃度预测模型对时序特征值进行处理,得到目标用户簇中各个用户在多个目标时段内的活跃度预测值;根据目标用户簇中各个用户在多个目标时段内的活跃度预测值,确定目标用户簇中的活跃用户,本公开通过时序聚类将各个用户按照浏览值和第一历史时段划分至不同的用户簇,得到目标用户簇,使一个目标用户簇内的用户具有相同或相似的分布,有效解决数据稀疏问题,从而提升预测的精确度,通过时序预测方法,可以针对电商领域中用户稀疏的历史行为数据构建活跃度预测模型,能够覆盖全体用户,用户活跃度准确率达到80%以上。

[0154] 所属技术领域的技术人员能够理解,本发明的各个方面可以实现为系统、方法或程序产品。因此,本发明的各个方面可以具体实现为以下形式,即:完全的硬件实施方式、完全的软件实施方式(包括固件、微代码等),或硬件和软件方面结合的实施方式,这里可以统称为“电路”、“模块”或“系统”。

[0155] 下面参照图8来描述根据本发明的这种实施方式的电子设备800。图8显示的电子设备800仅仅是一个示例,不应对本发明实施例的功能和使用范围带来任何限制。

[0156] 如图8所示,电子设备800以通用计算设备的形式表现。电子设备800的组件可以包括但不限于:上述至少一个处理单元810、上述至少一个存储单元820、连接不同系统组件

(包括存储单元820和处理单元810)的总线830。

[0157] 其中,存储单元存储有程序代码,程序代码可以被处理单元810执行,使得处理单元810执行本说明书上述“示例性方法”部分中描述的根据本发明各种示例性实施方式的步骤。例如,处理单元810可以执行如图2中所示的对各个用户在多个第一历史时段的浏览值进行时序聚类,得到目标用户簇;基于目标用户簇中各个用户在多个第二历史时段的行为数据,得到目标用户簇的时序特征值;基于预设活跃度预测模型对时序特征值进行处理,得到目标用户簇中各个用户在多个目标时段内的活跃度预测值,其中,目标时段为多个第二历史时段之后的时段;根据目标用户簇中各个用户在多个目标时段内的活跃度预测值,确定目标用户簇中的活跃用户。

[0158] 存储单元820可以包括易失性存储单元形式的可读介质,例如随机存取存储单元(RAM)8201和/或高速缓存存储单元8202,还可以进一步包括只读存储单元(ROM)8203。

[0159] 存储单元820还可以包括具有一组(至少一个)程序模块8205的程序/实用工具8204,这样的程序模块8205包括但不限于:操作系统、一个或者多个应用程序、其它程序模块以及程序数据,这些示例中的每一个或某种组合中可能包括网络环境的实现。

[0160] 总线830可以为表示几类总线结构中的一种或多种,包括存储单元总线或者存储单元控制器、外围总线、图形加速端口、处理单元或者使用多种总线结构中的任意总线结构的局域总线。

[0161] 电子设备800也可以与一个或多个外部设备840(例如键盘、指向设备、蓝牙设备等)通信,还可与一个或者多个使得用户能与该系统交互的设备通信,和/或与使得该电子设备800能与一个或多个其它计算设备进行通信的任何设备(例如路由器、调制解调器等)通信。这种通信可以通过输入/生成(I/O)接口850进行。并且,系统还可以通过网络适配器860与一个或者多个网络(例如局域网(LAN),广域网(WAN)和/或公共网络,例如因特网)通信。如图8所示,网络适配器860通过总线830与电子设备800的其它模块通信。应当明白,尽管图8中未示出,可以结合电子设备800使用其它硬件和/或软件模块,包括但不限于:微代码、设备驱动器、冗余处理单元、外部磁盘驱动阵列、RAID系统、磁带驱动器以及数据备份存储系统等。

[0162] 通过以上的实施方式的描述,本领域的技术人员易于理解,这里描述的示例实施方式可以通过软件实现,也可以通过软件结合必要的硬件的方式来实现。因此,根据本公开实施方式的技术方案可以以软件产品的形式体现出来,该软件产品可以存储在一个非易失性存储介质(可以是CD-ROM,U盘,移动硬盘等)中或网络上,包括若干指令以使得一台计算设备(可以是个人计算机、服务器、终端装置、或者网络设备等)执行根据本公开实施方式的方法。

[0163] 在本公开的示例性实施例中,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可以是可读信号介质或者可读存储介质。在本公开的示例性实施例中,还提供了一种计算机程序产品,计算机程序产品包括计算机程序或计算机指令,计算机程序或计算机指令由处理器加载并执行,以使计算机实现上述实施例公开的方法的步骤。

[0164] 本公开中的计算机可读存储介质的更具体的例子可以包括但不限于:具有一个或多个导线的电连接、便携式计算机磁盘、硬盘、随机访问存储器(RAM)、只读存储器(ROM)、可擦式可编程只读存储器(EPROM或闪存)、光纤、便携式紧凑磁盘只读存储器(CD-ROM)、光存

储器件、磁存储器件、或者上述的任意合适的组合。

[0165] 在本公开中,计算机可读存储介质可以包括在基带中或者作为载波一部分传播的数据信号,其中承载了可读程序代码。这种传播的数据信号可以采用多种形式,包括但不限于电磁信号、光信号或上述的任意合适的组合。可读信号介质还可以是可读存储介质以外的任何可读介质,该可读介质可以发送、传播或者传输用于由指令执行系统、装置或者器件使用或者与其结合使用的程序。

[0166] 可选地,计算机可读存储介质上包含的程序代码可以用任何适当的介质传输,包括但不限于无线、有线、光缆、RF等等,或者上述的任意合适的组合。

[0167] 在具体实施时,可以以一种或多种程序设计语言的任意组合来编写用于执行本公开操作的程序代码,程序设计语言包括面向对象的程序设计语言—诸如Java、C++等,还包括常规的过程式程序设计语言—诸如“C”语言或类似的设计语言。程序代码可以完全地在用户计算设备上执行、部分地在用户设备上执行、作为一个独立的软件包执行、部分在用户计算设备上部分在远程计算设备上执行、或者完全在远程计算设备或服务器上执行。在涉及远程计算设备的情形中,远程计算设备可以通过任意种类的网络,包括局域网(LAN)或广域网(WAN),连接到用户计算设备,或者,可以连接到外部计算设备(例如利用因特网服务提供商来通过因特网连接)。

[0168] 应当注意,尽管在上文详细描述中提及了用于动作执行的设备的若干模块或者单元,但是这种划分并非强制性的。实际上,根据本公开的实施方式,上文描述的两个或更多模块或者单元的特征和功能可以在一个模块或者单元中具体化。反之,上文描述的一个模块或者单元的特征和功能可以进一步划分为由多个模块或者单元来具体化。

[0169] 此外,尽管在附图中以特定顺序描述了本公开中方法的各个步骤,但是,这并非要求或者暗示必须按照该特定顺序来执行这些步骤,或是必须执行全部所示的步骤才能实现期望的结果。附加的或备选的,可以省略某些步骤,将多个步骤合并为一个步骤执行,以及/或者将一个步骤分解为多个步骤执行等。

[0170] 通过以上实施方式的描述,本领域的技术人员易于理解,这里描述的示例实施方式可以通过软件实现,也可以通过软件结合必要的硬件的方式来实现。因此,根据本公开实施方式的技术方案可以以软件产品的形式体现出来,该软件产品可以存储在一个非易失性存储介质(可以是CD-ROM,U盘,移动硬盘等)中或网络上,包括若干指令以使得一台计算设备(可以是个人计算机、服务器、移动终端、或者网络设备等)执行根据本公开实施方式的方法。

[0171] 本领域技术人员在考虑说明书及实践这里公开的发明后,将容易想到本公开的其它实施方案。本公开旨在涵盖本公开的任何变型、用途或者适应性变化,这些变型、用途或者适应性变化遵循本公开的一般性原理并包括本公开未公开的本技术领域中的公知常识或惯用技术手段。说明书和实施例仅被视为示例性的,本公开的真正范围和精神由所附的权利要求指出。




图1




图2




图3




图4




图5




图6




图7




图8