



(12) 发明专利

(10) 授权公告号 CN 118863975 B

(45) 授权公告日 2024. 12. 24

(21) 申请号 202411341622.0

G06N 3/042 (2023.01)

(22) 申请日 2024.09.25

G06N 3/0464 (2023.01)

G06N 3/0442 (2023.01)

(65) 同一申请的已公布的文献号

申请公布号 CN 118863975 A

(56) 对比文件

CN 116452269 A, 2023.07.18

(43) 申请公布日 2024.10.29

审查员 赵栖

(73) 专利权人 成都纳宝科技有限公司

地址 610095 四川省成都市中国(四川)自
由贸易试验区成都高新区锦城大道
666号4栋24层4号

(72) 发明人 肖轩 李学朋 刘行 杨思同

(74) 专利代理机构 成都正德明志知识产权代理
有限公司 51360

专利代理师 雷正

(51) Int. Cl.

G06Q 30/0201 (2023.01)

权利要求书3页 说明书18页 附图1页

(54) 发明名称

基于扩大消费频次与消费规模的智能化营
销系统

(57) 摘要

本发明属于数据分析与处理技术领域,具体涉及基于扩大消费频次与消费规模的智能化营销系统,所述系统包括:数据采集单元、图构建单元、特征提取单元、多关系图卷积模型分析单元和促销策略生成单元;所述数据采集单元,用于采集用户数据和产品数据;所述图构建单元,用于根据用户数据,创建用户节点集和产品节点集,得到多维产品与关系图;所述特征提取单元,用于提取多维产品与关系图的特征,得到特征提取结果;所述多关系图卷积模型分析单元,用于得到用户的嵌入表示和产品的嵌入表示;所述促销策略生成单元,用于为每个用户推荐匹配度超过设定阈值的产品。本发明有助于实现扩大消费频次和消费规模的目标。



1. 基于扩大消费频次与消费规模的智能化营销系统, 其特征在于, 所述系统包括: 数据采集单元、图构建单元、特征提取单元、多关系图卷积模型分析单元和促销策略生成单元; 所述数据采集单元, 用于采集用户数据和产品数据; 所述图构建单元, 用于根据用户数据, 创建用户节点集和产品节点集, 产品节点集中的每个节点代表一个产品, 用户节点集中的每个节点代表一个用户, 合并用户节点集和产品节点集组成总节点集; 根据用户数据, 确定所有可能的用户与产品的交互类型, 对于每种关系类型, 遍历所有用户与产品对, 如果存在交互, 则在用户节点和产品节点之间创建一条边, 并计算边的权重, 得到多维产品与关系图; 所述特征提取单元, 用于提取多维产品与关系图的特征, 得到特征提取结果; 所述多关系图卷积模型分析单元, 用于根据构建的多维产品与关系图和特征提取结果, 创建多关系图卷积网络, 对多关系卷积网络进行分析, 得到用户的嵌入表示和产品的嵌入表示; 所述促销策略生成单元, 用于根据用户的嵌入表示和产品的嵌入表示, 计算每个用户和产品的匹配度, 为每个用户推荐匹配度超过设定阈值的产品; 所述用户数据包括: 用户唯一标识符、用户行为和用户产品评价指数; 所述产品数据包括: 产品唯一标识符和产品价格; 所述用户行为包括: 购买、浏览、收藏、评论和加入购物车; 每一种用户行为对应一种用户与产品的交互类型; 数据采集单元的执行过程如下: 收集用户唯一标识符 U_i , 其中 $i \in \{1, 2, \dots, N\}$, N 为用户数量; 采集用户行为数据 $B_{i,j,r}$, 其中 $j \in \{1, 2, \dots, M\}$, M 为产品数量, $r \in \{1, 2, \dots, 5\}$ 表示5种行为类型; 记录用户产品评价指数 $R_{i,j} \in [0, 5]$; 收集产品唯一标识符 P_j , 其中 $j \in \{1, 2, \dots, M\}$; 记录产品价格 C_j ; 得到数据采集过程 $F_{collect}(U, P)$ 为:

$$F_{collect}(U, P) = \{(U_i, \{B_{i,j,r}\}, \{R_{i,j}\}), (P_j, C_j)\};$$

其中, U 代表用户集合, P 代表产品集合; 图构建单元的执行过程如下: 创建用户节点集 $V_U = \{U_i | i \in \{1, 2, \dots, N\}\}$; 创建产品节点集: $V_P = \{P_j | j \in \{1, 2, \dots, M\}\}$; 得到合并节点集 $V = V_U \cup V_P$; 对于每种用户行为 r , 创建边集 E_r :

$$E_r = \{(U_i, P_j, w_{i,j,r}) | B_{i,j,r} > 0\};$$

其中, $w_{i,j,r}$ 是用户 i 到产品 j 在用户行为类型 r 下的边的权重, 通过以下公式计算:

$$w_{i,j,r} = \frac{f_{ij}^r \cdot (1 + \log(m_{ij}^r))}{\sum_{k \in N_i} f_{ik}^r \cdot (1 + \log(m_{ik}^r))} \cdot \exp(-\lambda \cdot t_{ij}^r) \cdot (1 + R_{ij});$$

其中, f_{ij}^r 为用户行为类型 r 下的交互频次; m_{ij}^r 为用户行为类型 r 下的交互金额; t_{ij}^r 为用户 i 到产品 j 最后一次进行用户行为类型 r 的交互距今的时间; R_{ij} 为用户 i 到产品 j 的产品评价指数; λ 为预设的时间衰减因子; N_i 为用户 i 的邻居节点集合; k 为下标索引, 取值为正整

数;合并所有边集得到边集合 $E = \bigcup_{k=1}^5 E_k$; E_k 表示第 k 个边集;构建多维产品与关系图

$$G = (V, E); w_{i,j} = \sum_{r=1}^5 w_{i,j,r}.$$

2. 如权利要求1所述的基于扩大消费频次与消费规模的智能化营销系统,其特征在于,特征提取单元首先使用 L 层的卷积神经网络提取多维产品与关系图的特征,公式如下:

$$H^{(l+1)} = \sigma \left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W + \alpha \cdot \text{ReLU}(\text{BatchNorm}(H^{(l)})) + \beta \cdot \text{GRU}(H^{(l)}, H^{(l-1)}) \right);$$

其中,GRU是门控循环单元; $H^{(l)}$ 是第 l 层的节点特征矩阵; $H^{(l+1)}$ 是第 $l+1$ 层的节点特征矩阵; σ 是非线性激活函数; $\tilde{A} = A + I_N$ 是添加了自连接 I_N 的邻接矩阵; A 为邻接矩阵; $\tilde{D}$ 是 $\tilde{A}$ 的度矩阵; W 是权重矩阵,其中第 i 行,第 j 列的元素为 $w_{i,j}$;BatchNorm是批量归一化操作; α 和 β 均分别是预设的平衡不同组件贡献的超参数;最终的特征提取结果是最后一层的输出 $H^{(L)}$;设定产品权重为 C ,对于第 $l+1$ 层的节点特征矩阵

$$H^{(l+1)} = (1 - C)H_U^{(l+1)} + CH_P^{(l+1)}; H_U^{(l+1)}, H_P^{(l+1)} \text{ 分别是第 } l+1 \text{ 层的用户节点特征矩阵和产品节点特征矩阵。}$$

3. 如权利要求2所述的基于扩大消费频次与消费规模的智能化营销系统,其特征在于,多关系图卷积模型分析单元的执行过程具体包括:根据特征提取单元的输出结果,初始化用户节点特征矩阵 $H_U \in \mathbb{R}^{N \times d}$ 和产品节点特征矩阵 $H_P \in \mathbb{R}^{M \times d}$,其中 N 是用户数量, M 是产品数量, d 是特征维度;对于每种关系类型 $r \in \{1, 2, \dots, 5\}$,构建一个图卷积层,每层的更新规则如下:

$$H_U^{(l+1)} = \sigma \left(\sum_{r=1}^5 \tilde{D}_r^{-\frac{1}{2}} \tilde{A}_r \tilde{D}_r^{-\frac{1}{2}} H_U^{(l)} W_r + \text{GRU}(H_U^{(l)}, H_U^{(l-1)}) \right);$$

$$H_P^{(l+1)} = \sigma \left(\sum_{r=1}^5 \tilde{D}_r^{-\frac{1}{2}} \tilde{A}_r^T \tilde{D}_r^{-\frac{1}{2}} H_P^{(l)} W_r + \text{GRU}(H_P^{(l)}, H_P^{(l-1)}) \right);$$

其中: $\tilde{A}_r$ 是第 r 种交互类型的邻接矩阵加上自连接; $\tilde{D}_r$ 是 $\tilde{A}_r$ 的度矩阵; $W_r = \sum_{i=1}^N \sum_{j=1}^M w_{i,j,r}$;得到最终的图卷积层的输出为 $H_U^{(L)}$ 和 $H_P^{(L)}$;引入关系级别的注意力机制,计算每种交互类型的重要性 e_r ;根据每种关系的重要性 e_r ,使用多头注意力机制聚

合不同交互类型的表示,得到多头注意力结果;对每个多头注意力结果进行归一化操作,分别得到用户的最终嵌入表示 $E_U \in \mathbb{R}^{N \times d}$,以及产品的最终嵌入表示 E_P ; $\mathbb{R}$ 表示实数域。

4.如权利要求3所述的基于扩大消费频次与消费规模的智能化营销系统,其特征在于,通过如下公式,计算每种交互类型的重要性 e_r :

$$e_r = \frac{\exp(\tanh(X(F_{collect}(U,P)) \cdot [H_U^{(L)} \| H_P^{(L)}]))}{\sum_{r=1}^5 \exp(X(F_{collect}(U,P)) \cdot \tanh[H_U^{(L)} \| H_P^{(L)}])};$$

其中, $\|$ 表示拼接操作; $X(\cdot)$ 为求矩阵的秩的运算。

5.如权利要求4所述的基于扩大消费频次与消费规模的智能化营销系统,其特征在于,通过如下公式,使用多头注意力机制聚合不同交互类型的表示,得到多头注意力结果:

$$Z_U = \text{MultiHead}(H_U^{(L)}, H_P^{(L)}, H_P^{(L)});$$

$$Z_P = \text{MultiHead}(H_P^{(L)}, H_U^{(L)}, H_U^{(L)});$$

其中, Z_U 为用户的多头注意力结果; Z_P 为产品的多头注意力结果; $\text{MultiHead}()$ 函数定义为:

$$\text{MultiHead}() = \text{Concat}(\text{head}_1, \dots, \text{head}_h)W^O;$$

$$\text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V);$$

$$\text{Attention}() = \text{softmax}\left(\frac{QK^T}{\sqrt{d}}\right)V;$$

其中, h 为注意力头的数量; W^O 为多头注意力输出的线性变换矩阵; $\text{Attention}()$ 为注意力计算函数,计算查询和键之间的相似度,并用于加权值矩阵; K 为键矩阵; V 为值矩阵; Q 为查询矩阵; head_i 为第 i 个注意力头的输出; W_i 为第 i 个注意力头的线性变换矩阵; $\text{softmax}()$ 为 softmax 函数; T 为矩阵的转置运算。

6.如权利要求5所述的基于扩大消费频次与消费规模的智能化营销系统,其特征在于,所述促销策略生成单元,根据用户的嵌入表示和产品的嵌入表示,通过如下公式,计算每个用户和产品的匹配度 MO :

$$MO = \frac{E_U^T E_P}{\|E_U\| \|E_P\|} + \exp\left(-\lambda \cdot \frac{t_{\text{current}} - t_{ij}^r}{\max(N, t_{ij}^r)}\right) + \frac{1}{1 + \exp(1 - (\sum_{r=1}^5 \|W_r\|))};$$

其中, t_{current} 为当前时间; t_{ij}^r 为用户 i 到产品 j 最后一次进行用户行为类型 r 的交互距今的时间; $\|\cdot\|$ 为求向量的模的运算。

基于扩大消费频次与消费规模的智能化营销系统

技术领域

[0001] 本发明属于数据处理与分析技术领域,具体涉及基于扩大消费频次与消费规模的智能化营销系统。

背景技术

[0002] 随着数字化和信息技术的快速发展,智能化营销系统在电子商务和零售领域的应用越来越广泛。传统的营销方式逐渐被基于数据驱动的智能推荐系统所取代,这些系统通过分析用户的行为数据、兴趣偏好和消费习惯,能够在合适的时间向合适的用户推送合适的产品,极大地提高了营销的精准度和效率。现有技术主要依赖于推荐算法,如协同过滤算法、基于内容的推荐、以及混合推荐方法。这些技术虽然在一定程度上实现了个性化推荐,但在实际应用中依然存在诸多局限性和问题,未能充分满足不断变化的市场需求和用户期望。

[0003] 协同过滤算法是现有技术中最为常用的一种推荐方法,它基于用户之间的相似性或用户与物品之间的相似性来进行推荐。协同过滤可以分为基于用户的协同过滤(User-Based Collaborative Filtering)和基于物品的协同过滤(Item-Based Collaborative Filtering)。基于用户的协同过滤通过计算用户与用户之间的相似度,推荐与目标用户相似的其他用户喜欢的物品;而基于物品的协同过滤则是通过计算物品与物品之间的相似度,推荐与目标用户喜欢的物品相似的其他物品。然而,这些方法依赖于历史数据,容易受到数据稀疏性和冷启动问题的困扰。对于新用户或新产品,缺乏足够的历史交互数据,导致推荐结果的准确性大大降低。此外,协同过滤方法还存在着推荐结果单一化的问题,不能充分挖掘用户的潜在兴趣和多样化需求。基于内容的推荐(Content-Based Filtering)是另一种常见的推荐方法,它通过分析物品的内容信息(如物品描述、标签、特征等)来为用户推荐相似的物品。这种方法能够在一定程度上缓解协同过滤的冷启动问题,因为它不依赖于用户的历史行为数据。然而,基于内容的推荐同样面临一些挑战。首先,它需要对物品的特征进行详细的描述和结构化,这在实际应用中常常难以实现,尤其是对于那些没有明确特征的物品。其次,基于内容的推荐方法容易导致推荐结果过于狭窄,用户只能收到与他们已经喜欢的物品非常相似的推荐,缺乏多样性和新颖性。

发明内容

[0004] 鉴于此,本发明的主要目的在于提供基于扩大消费频次与消费规模的智能化营销系统,显著提升了智能化营销系统在用户与产品之间多种交互关系的建模和优化分析能力,从而有助于实现扩大消费频次和消费规模的目标。

[0005] 本发明采用的技术方案如下:

[0006] 基于扩大消费频次与消费规模的智能化营销系统,所述系统包括:数据采集单元、图构建单元、特征提取单元、多关系图卷积模型分析单元和促销策略生成单元;所述数据采集单元,用于采集用户数据和产品数据;所述图构建单元,用于根据用户数据,创建用户节

点集和产品节点集,产品节点集中的每个节点代表一个产品,用户节点集中的每个节点代表一个用户,合并用户节点集和产品节点集组成总节点集;根据用户数据,确定所有可能的用户与产品的交互类型,对于每种关系类型,遍历所有用户与产品对,如果存在交互,则在用户节点和产品节点之间创建一条边,并计算边的权重,得到多维产品与关系图;所述特征提取单元,用于提取多维产品与关系图的特征,得到特征提取结果;所述多关系图卷积模型分析单元,用于根据构建的多维产品与关系图和特征提取结果,创建多关系图卷积网络,对多关系卷积网络进行分析,得到用户的嵌入表示和产品的嵌入表示;所述促销策略生成单元,用于根据用户的嵌入表示和产品的嵌入表示,计算每个用户和产品的匹配度,为每个用户推荐匹配度超过设定阈值的产品。

[0007] 进一步的,所述用户数据包括:用户唯一标识符、用户行为和用户产品评价指数;所述产品数据包括:产品唯一标识符和产品价格;所述用户行为包括:购买、浏览、收藏、评论和加入购物车;每一种用户行为对应一种用户与产品的交互类型。

[0008] 进一步的,数据采集单元的执行过程如下:收集用户唯一标识符 U_i ,其中 $i \in \{1, 2, \dots, N\}$, N 为用户数量;采集用户行为数据 $B_{i,j,r}$,其中 $j \in \{1, 2, \dots, M\}$, M 为产品数量, $r \in \{1, 2, \dots, 5\}$ 表示5种行为类型;记录用户产品评价指数 $R_{i,j} \in [0, 5]$;收集产品唯一标识符 P_j ,其中 $j \in \{1, 2, \dots, M\}$;记录产品价格 C_j ;得到数据采集过程 $F_{collect}(U, P)$ 为:

[0009] $F_{collect}(U, P) = \{(U_i, \{B_{i,j,r}\}, \{R_{i,j}\}), (P_j, C_j)\};$

[0010] 其中, U 代表用户集合, P 代表产品集合。

[0011] 进一步的,图构建单元的执行过程如下:创建用户节点集 $V_U = \{U_i | i \in \{1, 2, \dots, N\}\}$;创建产品节点集: $V_P = \{P_j | j \in \{1, 2, \dots, M\}\}$;得到合并节点集 $V = V_U \cup V_P$;对于每种用户行为 r ,创建边集 E_r :

[0012] $E_r = \{(U_i, P_j, w_{i,j,r}) | B_{i,j,r} > 0\};$

[0013] 其中, $w_{i,j,r}$ 是用户 i 到产品 j 在用户行为类型 r 下的边的权重,通过以下公式计算:

[0014] $w_{i,j,r} = \frac{f_{ij}^r \cdot (1 + \log(m_{ij}^r))}{\sum_{k \in N_i} f_{ik}^r \cdot (1 + \log(m_{ik}^r))} \cdot \exp(-\lambda \cdot t_{ij}^r) \cdot (1 + R_{ij});$

[0015] 其中, f_{ij}^r 为用户行为类型 r 下的交互频次; m_{ij}^r 为用户行为类型 r 下的交互金额; t_{ij}^r 为用户 i 到产品 j 最后一次进行用户行为类型 r 的交互距今的时间; R_{ij} 为用户 i 到产品 j 的产品评价指数; λ 为预设的时间衰减因子; N_i 为用户 i 的邻居节点集合; k 为下标索引,取值为正整数;合并所有边集得到边集合 $E = \bigcup_{k=1}^5 E_k$;构建多维产品与关系图 $G = (V, E)$;

$$w_{i,j} = \sum_{r=1}^5 w_{i,j,r}.$$

[0016] 进一步的,特征提取单元首先使用 L 层的卷积神经网络提取多维产品与关系图的特征,公式如下:

$$H^{(l+1)} = \sigma \left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W + \alpha \cdot \text{ReLU}(\text{BatchNorm}(H^{(l)})) + \beta \cdot \text{GRU}(H^{(l)}, H^{(l-1)}) \right);$$

[0018] 其中,GRU是门控循环单元; $H^{(l)}$ 是第 l 层的节点特征矩阵; $H^{(l+1)}$ 是第 $l+1$ 层的节点特征矩阵; σ 是非线性激活函数; $\tilde{A} = A + I_N$ 是添加了自连接 I_N 的邻接矩阵; A 为邻接矩阵; $\tilde{D}$ 是 $\tilde{A}$ 的度矩阵; W 是权重矩阵,其中第 i 行,第 j 列的元素为 $w_{i,j}$;BatchNorm是批量归一化操作; α 和 β 均分别是预设的平衡不同组件贡献的超参数;最终的特征提取结果是最后一层的输出 $H^{(L)}$;设定产品权重为 C ,对于第 $l+1$ 层的节点特征矩阵 $H^{(l+1)} = (1 - C)H_U^{(l+1)} + CH_P^{(l+1)}$; $H_U^{(l+1)}$, $H_P^{(l+1)}$ 分别是第 $l+1$ 层的用户节点特征矩阵和产品节点特征矩阵。

[0019] 进一步的,多关系图卷积模型分析单元的执行过程具体包括:根据特征提取单元的输出结果,初始化用户节点特征矩阵 $H_U \in \mathbb{R}^{N \times d}$ 和产品节点特征矩阵 $H_P \in \mathbb{R}^{M \times d}$,其中 N 是用户数量, M 是产品数量, d 是特征维度;对于每种关系类型 $r \in \{1, 2, \dots, 5\}$,构建一个图卷积层,每层的更新规则如下:

$$[0020] \quad H_U^{(l+1)} = \sigma \left(\sum_{r=1}^5 \tilde{D}_r^{-\frac{1}{2}} \tilde{A}_r \tilde{D}_r^{-\frac{1}{2}} H_U^{(l)} W_r + \text{GRU}(H_U^{(l)}, H_U^{(l-1)}) \right);$$

$$[0021] \quad H_P^{(l+1)} = \sigma \left(\sum_{r=1}^5 \tilde{D}_r^{-\frac{1}{2}} \tilde{A}_r^T \tilde{D}_r^{-\frac{1}{2}} H_P^{(l)} W_r + \text{GRU}(H_P^{(l)}, H_P^{(l-1)}) \right);$$

[0022] 其中: $\tilde{A}_r$ 是第 r 种交互类型的邻接矩阵加上自连接; $\tilde{D}_r$ 是 $\tilde{A}_r$ 的度矩阵; $W_r = \sum_{i=1}^N \sum_{j=1}^M w_{i,j,r}$;得到最终的图卷积层的输出为 $H_U^{(L)}$ 和 $H_P^{(L)}$;引入关系级别的注意力机制,计算每种交互类型的重要性 e_r ;根据每种关系的重要性 e_r ,使用多头注意力机制聚合不同交互类型的表示,得到多头注意力结果;对每个多头注意力结果进行归一化操作,分别得到用户的最终嵌入表示 $E_U \in \mathbb{R}^{N \times d}$,以及产品的最终嵌入表示 E_P ; $\mathbb{R}$ 表示实数域。

[0023] 进一步的,通过如下公式,计算每种交互类型的重要性 e_r :

$$[0024] \quad e_r = \frac{\exp(\tanh(X(F_{collect}(U,P)) \cdot [H_U^{(L)} || H_P^{(L)}]))}{\sum_{r=1}^5 \exp(X(F_{collect}(U,P)) \cdot \tanh[H_U^{(L)} || H_P^{(L)}])};$$

[0025] 其中, $||$ 表示拼接操作; $X(\cdot)$ 为求矩阵的秩的运算。

[0026] 进一步的,通过如下公式,使用多头注意力机制聚合不同交互类型的表示,得到多头注意力结果:

$$[0027] \quad Z_U = \text{MultiHead}(H_U^{(L)}, H_P^{(L)}, H_P^{(L)});$$

$$[0028] \quad Z_P = \text{MultiHead}(H_P^{(L)}, H_U^{(L)}, H_U^{(L)});$$

[0029] 其中, Z_U 为用户的多头注意力结果; Z_P 为产品的多头注意力结果; $\text{MultiHead}()$ 函数定义为:

$$[0030] \quad \text{MultiHead}() = \text{Concat}(\text{head}_1, \dots, \text{head}_h)W^O;$$

$$[0031] \quad \text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V);$$

$$[0032] \quad \text{Attention}() = \text{softmax}\left(\frac{QK^T}{\sqrt{d}}\right)V;$$

[0033] 其中, h 为注意力头的数量; W^O 为多头注意力输出的线性变换矩阵; $\text{Attention}()$ 为注意力计算函数,计算查询和键之间的相似度,并用于加权值矩阵; K 为键矩阵; V 为值矩阵; Q 为查询矩阵; head_i 为第 i 个注意力头的输出; W_i 为第 i 个注意力头的线性变换矩阵; $\text{softmax}()$ 为 softmax 函数; T 为矩阵的转置运算。

[0034] 进一步的,所述促销策略生成单元,根据用户的嵌入表示和产品的嵌入表示,通过如下公式,计算每个用户和产品的匹配度 MO :

$$[0035] \quad MO = \frac{E_U^T E_P}{\|E_U\| \|E_P\|} + \exp\left(-\lambda \cdot \frac{t_{\text{current}} - t_{ij}^r}{\max(N, t_{ij}^r)}\right) + \frac{1}{1 + \exp(1 - (\sum_{r=1}^5 \|W_r\|))};$$

[0036] 其中, t_{current} 为当前时间; t_{ij}^r 为用户 i 到产品 j 最后一次进行用户行为类型 r 的交互距今的时间; $\|\cdot\|$ 为求向量的模的运算。

[0037] 采用以上技术方案,本发明产生了以下有益效果:本发明通过构建多关系图,全面捕捉了用户与产品之间的多维度交互信息。在现有的推荐系统中,通常只考虑用户与产品之间的一种或几种简单的交互关系,例如购买和浏览,而忽略了用户与产品之间可能存在的其他有价值的交互类型(如评论、收藏、分享等)。本发明利用多关系图的建模能力,能够同时处理多种类型的交互信息,从而更全面地了解用户的兴趣和偏好。例如,通过分析用户

的浏览历史和评论行为,系统可以更准确地判断用户对某一产品的兴趣深度,而不仅仅是根据购买行为来做出判断。这种多维度的关系建模不仅提高了推荐结果的相关性和覆盖度,还显著提升了用户体验和满意度。其次,利用多关系图卷积网络,本发明实现了对不同交互类型的精细化建模和特征提取。传统的图卷积网络在处理单一关系图时具有较好的性能,但在面对多关系图时,往往难以有效建模不同关系类型之间的相互作用。本发明的MR-GCN通过在图卷积层中引入多关系类型的邻接矩阵和度矩阵,可以分别对每种关系类型进行卷积操作,捕捉每种交互类型的特征和模式。这样一来,系统能够在高维特征空间中更准确地学习到不同交互类型对用户消费决策的影响力,使得推荐策略更加精准。例如,对于那些在浏览和收藏行为上表现活跃但购买行为较少的用户,系统可以识别出他们的潜在兴趣,并通过个性化的推荐策略激发他们的购买意愿,从而增加消费频次。本发明的另一大有益效果体现在对时间因素的充分考虑和动态响应能力的提升。用户的兴趣和行为习惯是动态变化的,尤其是在竞争激烈的市场环境中,用户的偏好可能会随着时间的推移迅速变化。传统的推荐系统通常难以快速适应这种变化,因为它们缺乏对时间因素的动态建模能力。本发明通过在匹配度计算公式中引入时间衰减因子,能够根据用户行为的时间维度调整推荐策略,使得系统对近期的用户行为给予更高的权重,而对较早前的行为逐渐降低影响。这种时间敏感的推荐机制使得系统能够实时捕捉用户兴趣的变化,提供更加及时和相关的推荐,进而提高用户的粘性和消费频次。

附图说明

[0038] 图1为本发明实施例提供的基于扩大消费频次与消费规模的智能化营销系统的系统结构示意图。

具体实施方式

[0039] 本说明书中公开的所有特征,或公开的所有方法或过程中的步骤,除了互相排斥的特征和/或步骤以外,均可以以任何方式组合。

[0040] 本说明书(包括任何附加权利要求、摘要)中公开的任一特征,除非特别叙述,均可被其他等效或具有类似目的的替代特征加以替换。即,除非特别叙述,每个特征只是一系列等效或类似特征中的一个例子而已。

[0041] 实施例1:参考图1,基于扩大消费频次与消费规模的智能化营销系统,所述系统包括:数据采集单元、图构建单元、特征提取单元、多关系图卷积模型分析单元和促销策略生成单元;所述数据采集单元,用于采集用户数据和产品数据;所述图构建单元,用于根据用户数据,创建用户节点集和产品节点集,产品节点集中的每个节点代表一个产品,用户节点集中的每个节点代表一个用户,合并用户节点集和产品节点集组成总节点集;根据用户数据,确定所有可能的用户与产品的交互类型,对于每种关系类型,遍历所有用户与产品对,如果存在交互,则在用户节点和产品节点之间创建一条边,并计算边的权重,得到多维产品与关系图;所述特征提取单元,用于提取多维产品与关系图的特征,得到特征提取结果;所述多关系图卷积模型分析单元,用于根据构建的多维产品与关系图和特征提取结果,创建多关系图卷积网络,对多关系卷积网络进行分析,得到用户的嵌入表示和产品的嵌入表示;所述促销策略生成单元,用于根据用户的嵌入表示和产品的嵌入表示,计算每个用户和产

品的匹配度,为每个用户推荐匹配度超过设定阈值的产品。

[0042] 具体的,数据采集单元在基于扩大消费频次与消费规模的智能化营销系统中扮演着至关重要的角色,其核心原理是通过多渠道、多维度的数据收集,为系统的后续分析和决策提供丰富且精确的数据基础。在这个单元中,系统首先通过在线和线下的多种途径,实时地收集用户的行为数据和产品的相关数据。用户行为数据主要包括用户的购买记录、浏览记录、点击率、收藏和评价等互动行为,这些行为反映了用户对不同产品的兴趣和偏好。此外,系统还采集用户的基本人口统计数据,例如年龄、性别、地理位置、职业和收入水平等,这些数据可以帮助系统更好地理解用户的背景和消费能力,从而进行更精准的营销策略设计。另一方面,产品数据包括产品的类别、价格、销量、评价等信息,这些数据不仅用于描绘产品的市场表现,还用于识别产品的竞争力和用户接受度。通过整合这些多维度的数据,数据采集单元能够构建出一个全面的用户画像和产品画像。在实际应用中,数据采集单元不仅依赖传统的数据获取方式,如商场POS系统、CRM系统中的交易记录,还会结合现代互联网数据来源,如电商平台、社交媒体、移动应用程序的用户行为数据。这种多渠道的数据采集方式能够确保数据的多样性和全面性,从而增强系统的智能化分析能力。更为重要的是,数据采集单元引入了实时数据更新的机制,这意味着系统可以在用户行为发生的同时,立即获取并更新相应的数据。这种实时性的数据采集能力显著提升了系统对用户需求变化的敏感度和响应速度,使得系统能够动态调整营销策略,及时抓住市场机会。此外,为了提高数据的准确性和有效性,数据采集单元还利用了多种数据清洗和预处理技术。例如,系统会自动过滤掉无效数据和噪声数据,采用数据标准化和归一化技术处理异常值和数据偏差,确保输入的数据质量符合后续分析的要求。这些数据预处理技术在优化数据质量的同时,也有助于提升系统的整体运行效率。通过数据采集单元的全方位数据收集和处理,系统能够获取到精确且全面的用户和产品数据,从而为后续的图构建、特征提取、多关系图卷积分析等模块提供强有力的数据支持。这种基于多渠道、多维度、实时动态更新的数据采集机制,使得智能化营销系统在扩大消费频次和消费规模的目标上,能够更精准地识别和预测用户的消费行为,制定更具针对性的营销策略,提高用户的粘性和购买意愿,最终实现营销效果的最大化。

[0043] 图构建单元是基于扩大消费频次与消费规模的智能化营销系统中最为关键的模块之一,其主要原理在于将复杂的用户与产品数据转化为一种图结构,以便进一步分析和优化营销策略。这个单元的设计基于这样一个核心理念:通过构建用户和产品之间的多维交互关系图,可以更全面和精细地反映用户行为与产品特性之间的复杂关系,从而为智能化推荐和精准营销提供更强有力的支持。在智能化营销系统中,图构建单元首先需要根据数据采集单元所提供的用户和产品数据,建立用户节点集和产品节点集。每一个用户节点代表一个个体用户,包含其基本信息、行为数据以及相关的特征属性,而每一个产品节点则代表一个具体的产品,包含产品的分类、价格、评价等信息。用户节点集和产品节点集共同构成了系统的基本节点集,通过这些节点集,系统能够清晰地描绘出用户和产品的基本信息以及它们各自的特征。

[0044] 图构建的核心在于创建用户节点和产品节点之间的边,即关系,这些边代表用户与产品之间的交互行为,例如购买、浏览、评论等。为了构建这些边,系统会先根据用户的行为数据,分析所有可能的用户与产品的交互类型,这些类型可能包括购买行为、加入购物车

车、商品收藏、浏览记录、产品评价等。对于每一种交互类型,系统会遍历所有用户与产品对,如果某一用户与某一产品之间存在某种特定类型的交互行为,系统就会在相应的用户节点和产品节点之间创建一条边。这些边的建立不仅仅是对用户和产品之间直接关系的简单映射,更是对用户行为背后复杂偏好和潜在需求的深层次刻画。每条边都会被赋予一定的权重,这个权重通常由用户与产品之间的交互强度、频次或重要性来决定。权重的设定是图构建中的一个重要步骤,因为它直接影响到后续的图分析和营销策略生成。在权重设定的过程中,系统会考虑多种因素,例如用户购买某一产品的次数、最近一次购买时间、用户对产品的评分等。通过这些多维度的数据,系统能够计算出每条边的合理权重,确保图结构能够真实、准确地反映用户与产品之间的互动关系和偏好程度。在完成用户节点和产品节点的边创建之后,图构建单元还会进一步优化整个图结构。这种优化不仅包括节点和边的简单增加或减少,还涉及到对图的全局结构进行调整,例如消除冗余连接、合并相似节点、平衡图的密度等。通过这些优化操作,系统可以确保图结构的简洁性和有效性,提高后续分析的准确性和计算效率。图构建单元的一个重要创新在于它能够支持多维关系图的构建。与传统的单一关系图不同,多维关系图可以在一个图结构中同时描述多种不同的关系类型,这对于复杂的用户行为分析尤为重要。例如,用户对同一产品的购买行为和浏览行为可以分别用两种不同类型的边来表示,这样的设计能够捕捉到用户行为的多样性和复杂性,从而更准确地预测用户的未来行为和偏好。在多维关系图中,图构建单元会为每种关系类型创建独立的子图,这些子图共享相同的节点集,但边集不同,每个子图代表一种特定的用户-产品交互类型。通过这种方式,系统可以在同一框架下,同时分析多种关系的影响,从而在生成促销策略时考虑更多维度的因素。图构建单元还具备动态更新的能力,这使得它能够实时响应用户行为和市场环境的变化。随着用户行为数据的不断更新,系统能够动态调整图结构,添加新的节点和边,或是更新现有节点和边的权重。这种动态调整机制使得系统能够在快速变化的市场环境中保持高效和精准,及时响应用户的需求变化和市场趋势,优化营销策略。在具体应用中,图构建单元的这些特性使得它能够全面刻画用户与产品之间的复杂关系,为后续的多关系图卷积分析和智能化推荐提供强有力的数据支持。通过这种方式,系统可以更好地理解用户的行为模式和消费习惯,预测用户未来的消费倾向,并制定个性化的促销策略,最终实现扩大消费频次与消费规模的目标。

[0045] 特征提取单元首先对多维产品与关系图进行深度分析,这一过程涉及多种图分析技术和机器学习方法的结合应用。在特征提取的初始阶段,系统会分析图中的节点特征和边特征。节点特征包括用户节点和产品节点的属性信息,例如用户的基本人口统计特征、购买行为特征,以及产品的类别、价格和市场表现等。边特征则反映了用户与产品之间的交互强度和频次,例如用户对某一产品的购买次数、浏览时长、评分等。通过对这些节点和边特征的提取和分析,系统能够初步构建用户和产品的特征向量,为进一步的分析提供基础。然而,简单的节点和边特征并不能完全揭示用户与产品之间的复杂关系,因此特征提取单元进一步采用高级的图卷积操作,以更好地捕捉高阶关系和特征交互。图卷积网络(GCN)是一种适用于图结构数据的神经网络模型,通过对图中的节点及其邻居节点的信息进行聚合,GCN能够捕捉到节点在图中位置的重要性和其与其他节点的关系。在本发明的智能化营销系统中,多关系图卷积网络(MR-GCN)被应用于特征提取过程。与传统的GCN不同,MR-GCN能够在多个关系维度上进行特征聚合和学习,从而提取出用户与产品在不同交互类型下的综

合特征表示。这种方法能够有效识别用户的多种行为模式,例如在某些情况下用户可能更倾向于购买特定类型的产品,而在其他情况下则更倾向于浏览和比较多种产品。通过学习这些复杂的行为模式和特征交互,系统能够更精准地预测用户的消费意图,并相应调整营销策略。此外,特征提取单元还采用了自注意力机制(Self-AttentionMechanism)来增强特征学习的效果。自注意力机制能够根据节点的重要性自动调整特征的权重,使得系统在特征提取过程中更加注重与营销目标紧密相关的特征,从而提高营销策略的精准度。例如,如果某一用户在近期频繁购买某类产品,自注意力机制将自动增加该用户节点及其相关边的权重,使得这些特征在后续分析中具有更高的影响力。特征提取单元的另一个重要功能是处理图中的噪声和冗余特征。在实际应用中,由于用户行为的复杂性和数据采集的多样性,图结构中难免会存在一些不相关或冗余的特征。为了确保系统的分析精度和效率,特征提取单元引入了特征选择和降维技术,如主成分分析(PCA)和图正则化方法。这些技术能够有效去除噪声特征和冗余信息,仅保留最具代表性和最能反映用户偏好的核心特征,从而优化系统的整体性能。

[0046] 多关系图卷积模型分析单元首先从图构建单元获取多维产品与关系图,这个图不仅包含了用户和产品的节点,还包含了代表用户与产品之间多种交互关系的边,例如购买、浏览、评价、收藏等。每种交互关系在图中被表示为不同类型的边,而这些边反映了用户和产品之间的不同维度的联系。传统的图卷积网络(GraphConvolutionalNetwork,GCN)在处理这类图时,通常仅考虑单一类型的关系,这对于真实世界中复杂的用户行为来说,显然是不够的。因此,本发明引入了多关系图卷积网络(MR-GCN),它能够在多个关系维度上同时进行特征学习,捕捉到用户与产品之间的复杂多样的交互模式。

[0047] 在多关系图卷积模型分析单元中,MR-GCN通过逐层卷积操作,逐步聚合节点的特征信息。这种聚合不仅限于直接相邻节点之间的简单特征整合,而是能够将来自不同关系类型的特征进行联合学习。具体来说,MR-GCN会为每一种关系类型分别构建卷积核,这些卷积核用于捕捉特定关系下的节点特征交互。在每一层卷积操作中,节点会根据其邻居节点的信息以及边的权重,更新其自身的特征表示。随着卷积层数的增加,节点的特征表示不仅包含了其直接邻居的信息,还逐步整合了更远邻居的特征,从而形成了一个多层次、多角度的特征表达。这种特征表达能够揭示用户在不同关系类型下的行为模式,例如在购买行为下的高频互动可能反映了用户的强烈购买意图,而在浏览行为下的长时间停留则可能指向用户的潜在兴趣。通过捕捉这些复杂的行为模式,系统能够更加精准地预测用户的未来行为,并制定相应的营销策略。此外,多关系图卷积模型分析单元还通过自注意力机制(Self-AttentionMechanism)进一步提升了特征学习的精度和效果。自注意力机制能够在特征聚合过程中自动调节各个关系类型的重要性权重,使得系统在学习过程中能够更加关注对预测任务最有贡献的关系类型。例如,当用户的购买行为与系统的营销目标高度相关时,自注意力机制会自动提升购买行为边的权重,从而增加该关系类型在特征学习过程中的影响力。这种动态调整机制使得多关系图卷积网络能够更好地适应复杂的用户行为模式,并在多种关系维度上实现更高效、更精准的特征学习。在特征学习的基础上,多关系图卷积模型分析单元进一步生成用户和产品的嵌入表示。嵌入表示是一种低维的向量表示,它能够在在一个紧凑的向量空间中表达用户和产品的多种特征。这种低维表示不仅减小了数据的存储和计算开销,还能够显著提高后续模型的计算效率。在生成嵌入表示后,系统会进一步计算

每个用户与产品之间的匹配度。匹配度的计算通常基于用户和产品的嵌入向量的相似度,例如通过余弦相似度、欧氏距离等度量方式来衡量。高匹配度通常表示用户对某一产品具有较高的兴趣或购买意向,系统可以根据这一信息,为用户推荐最合适的产品,进而实现精准营销和销售转化的目标。值得一提的是,多关系图卷积模型分析单元还具备动态调整和自我优化的能力。随着时间的推移和用户行为数据的不断更新,系统能够通过在线学习机制,动态更新图结构和节点的特征表示,从而不断优化其对用户行为的预测精度。这种动态调整能力使得系统在面对快速变化的市场环境和多变的用户行为时,依然能够保持高效的分析和预测能力,及时响应市场变化,优化营销策略,达到扩大消费频次和消费规模的目的。

[0048] 在确定匹配度之后,系统会根据设定的阈值筛选出那些与用户高度匹配的产品,作为候选促销对象。与传统的促销策略不同,本发明的系统能够实现精准的用户定位和产品推荐。通过将高匹配度的产品优先推荐给相应用户,系统不仅提高了促销的有效性,也显著提升了用户的购买意愿和消费频次。进一步地,促销策略生成单元还能够根据不同用户群体的特点和产品生命周期,动态调整促销策略。比如,对于忠诚度较高的用户,系统可能会推荐新产品或高利润产品,以刺激用户的消费欲望;而对于消费频次较低的用户,系统则可能提供折扣或优惠券等吸引措施,以提高用户的活跃度和参与度。此外,该单元还能够根据实时市场数据和用户反馈,进行策略的自我优化和调整。这意味着,当市场环境发生变化或者用户行为模式出现新的趋势时,系统能够及时调整促销策略,确保营销活动的灵活性和高效性。通过这样的动态优化机制,促销策略生成单元能够始终保持与用户需求和市场趋势的高度一致性,最大程度地提升销售转化率和客户满意度。总体而言,促销策略生成单元通过精确的匹配度计算和动态调整能力,实现了智能化营销系统在扩大消费频次和规模方面的核心目标,展示了其在精准营销和用户体验优化方面的显著优势。

[0049] 实施例2:所述用户数据包括:用户唯一标识符、用户行为和用户产品评价指数;所述产品数据包括:产品唯一标识符和产品价格;所述用户行为包括:购买、浏览、收藏、评论和加入购物车;每一种用户行为对应一种用户与产品的交互类型。

[0050] 具体的,用户数据包含用户唯一标识符、用户行为和用户产品评价指数,这三部分数据共同构成了一个完整的用户画像。用户唯一标识符是用于标记每个用户的唯一ID,这确保了系统能够准确地跟踪和记录每个用户的所有行为和交互。用户行为数据包括购买、浏览、收藏、评论和加入购物车等,这些行为数据代表了用户与产品的多种交互方式,每种行为对应着用户在购物过程中的不同阶段和心理状态。例如,购买行为直接反映了用户的消费决策和偏好,而浏览和收藏行为则可能表示用户对某一产品的潜在兴趣。此外,评论行为能够揭示用户对产品的使用体验和满意度,加入购物车则通常是购买决策前的准备行为。通过分析这些行为数据,系统能够更加精准地预测用户的消费意图,并制定相应的营销策略。同时,用户产品评价指数作为用户数据的重要组成部分,提供了用户对不同产品的主观评分,这种评分可以是星级评价、文字评论或者打分系统等多种形式。这种主观评价数据为系统提供了一个重要的参考维度,使得系统不仅能依靠用户的行为轨迹进行推荐,还可以结合用户的感性评价来优化推荐的精准度。结合用户行为和评价指数,系统可以更加全面地了解用户的偏好、需求和痛点,从而制定更具个性化和针对性的促销策略。另一方面,产品数据则主要包括产品唯一标识符和产品价格。产品唯一标识符用于区分不同的产品,

这使得系统能够精准地跟踪每个产品的销售情况和用户反馈。产品价格则是影响用户购买决策的重要因素之一,在智能化营销系统中,价格信息可以用于分析用户对不同价格区间产品的偏好,也可以用于制定差异化的定价策略和促销活动。例如,对于价格敏感的用户群体,系统可能会倾向于推荐价格较低的产品或提供价格优惠的信息,以提高这些用户的购买转化率每一种用户行为都对应一种用户与产品的交互类型,形成了丰富多样的用户-产品关系数据。这些关系数据通过多关系图的方式进行建模,为后续的多关系图卷积模型分析提供了坚实的数据基础。通过分析不同用户行为所形成的多种交互类型,系统可以识别出用户在不同场景下的消费模式和偏好特征,进而为每个用户生成最符合其消费习惯和需求的产品推荐和促销策略。总体而言,实施例2通过精细化的用户数据和产品数据设计,使得智能化营销系统能够更加全面、准确地捕捉用户行为和产品特征,进而实现更为精准的营销决策和策略优化,真正达到了扩大消费频次与消费规模的目标。

[0051] 实施例3:数据采集单元的执行过程如下:收集用户唯一标识符 U_i ,其中 $i \in \{1,2,\dots,N\}$, N 为用户数量;采集用户行为数据 $B_{i,j,r}$,其中 $j \in \{1,2,\dots,M\}$, M 为产品数量, $r \in \{1,2,\dots,5\}$ 表示5种行为类型;记录用户产品评价指数 $R_{i,j} \in [0,5]$;收集产品唯一标识符 P_j ,其中 $j \in \{1,2,\dots,M\}$;记录产品价格 C_j ;得到数据采集过程 $F_{collect}(U,P)$ 为:

$$[0052] \quad F_{collect}(U,P) = \{(U_i, \{B_{i,j,r}\}, \{R_{i,j}\}), (P_j, C_j)\};$$

[0053] 其中, U 代表用户集合, P 代表产品集合。

[0054] 具体的,在这个系统中,数据采集单元的设计是基于一个深刻的认知,即用户的消费行为是多样且复杂的,仅依靠单一的数据维度很难准确描绘用户的真实需求和兴趣。因此,实施例3通过收集用户唯一标识符、用户行为数据和用户产品评价指数等多种数据类型,建立了一个多维度的数据模型。这种数据模型不仅记录了用户的基本信息和历史行为,还涵盖了用户对不同产品的主观评价和情感反馈。通过这种多维度的数据收集方式,系统能够更好地理解用户的消费路径和决策过程。例如,用户行为数据中的购买、浏览、收藏、评论和加入购物车等行为类型,反映了用户在购物过程中的不同阶段和决策意图,而这些行为之间的相互关系可以揭示用户的购买动机和潜在需求。同时,系统还特别关注用户的产品评价指数,这是用户在消费过程中产生的主观数据,能够提供比单纯的行为数据更丰富的情感和偏好信息。通过结合行为数据和评价数据,系统不仅能够分析用户对特定产品的兴趣,还能够深入了解用户对产品质量、价格、服务等因素的态度,从而更准确地预测用户未来的消费行为。这种数据的结合使得系统能够在多维度上捕捉用户的偏好模式,为营销策略的制定提供更为可靠的依据。在产品数据方面,系统通过采集产品的唯一标识符和价格等信息,进一步丰富了数据模型的深度。产品标识符使系统能够跟踪每个产品的市场表现和用户反馈,而价格数据则为理解用户的价格敏感度和市场定位提供了重要的参考。价格信息在用户决策过程中扮演着关键角色,用户对价格的敏感度直接影响其购买决策和消费频次。通过分析这些数据,系统可以为不同的用户群体设计差异化的价格策略和促销活

动,以最大化销售转化率和用户参与度。数据采集过程的核心在于其结构化和标准化的设计,确保了数据的完整性和一致性,使得系统能够在后续的分析过程中高效地处理和利用这些数据。通过函数 $F_{\text{collect}}(U, P)$,系统能够将用户和产品数据有机结合,形成一个结构化的数据集合。这一集合不仅提供了用户与产品之间的关系,还揭示了这些关系背后的潜在模式和趋势,为多关系图卷积模型分析单元提供了必要的的数据支持。这种方法有效地提升了数据的利用效率,使得智能化营销系统能够在庞大且复杂的数据环境中快速、精准地识别出用户需求和市场机会。

[0055] 实施例4:图构建单元的执行过程如下:创建用户节点集 $V_U = \{U_i | i \in \{1, 2, \dots, N\}\}$;创建产品节点集: $V_P = \{P_j | j \in \{1, 2, \dots, M\}\}$;得到合并节点集 $V = V_U \cup V_P$;对于每种用户行为 r ,创建边集 E_r :

$$[0056] \quad E_r = \{(U_i, P_j, w_{i,j,r}) | B_{i,j,r} > 0\};$$

[0057] 其中, $w_{i,j,r}$ 是用户 i 到产品 j 在用户行为类型 r 下的边的权重,通过以下公式计算:

$$[0058] \quad w_{i,j,r} = \frac{f_{ij}^r \cdot (1 + \log(m_{ij}^r))}{\sum_{k \in N_i} f_{ik}^r \cdot (1 + \log(m_{ik}^r))} \cdot \exp(-\lambda \cdot t_{ij}^r) \cdot (1 + R_{ij});$$

[0059] 其中, f_{ij}^r 为用户行为类型 r 下的交互频次; m_{ij}^r 为用户行为类型 r 下的交互金额; t_{ij}^r 为用户 i 到产品 j 最后一次进行用户行为类型 r 的交互距今的时间; R_{ij} 为用户 i 到产品 j 的产品评价指数; λ 为预设的时间衰减因子; N_i 为用户 i 的邻居节点集合; k 为下标索引,取值为正整数;合并所有边集得到边集合 $E = \bigcup_{k=1}^5 E_k$;构建多维产品与关系图 $G = (V, E)$;

$$w_{i,j} = \sum_{r=1}^5 w_{i,j,r}.$$

[0060] 具体的,在实施例4中,图构建单元通过精心设计的公式,将用户与产品之间的多种交互行为映射为图结构中的边及其权重,这种设计为智能化营销系统提供了多维度的关系数据,使得系统能够更准确地捕捉用户的行为特征和消费偏好。公式的核心原理是通过综合考虑交互频次、交互金额、时间因素和用户评价等多个维度的因素来计算边的权重,从而实现对用户与产品之间复杂关系的精准建模。首先,公式中考虑了用户与产品之间的交互频次 f_{ij}^r ,这是反映用户行为强度的一个关键因素。频次越高,意味着用户对该产品的关注度和兴趣越大,因此在权重计算中,交互频次作为一个直接的乘子,显著影响边的权重。然而,频次本身并不能全面反映用户与产品之间的关系强度,尤其是在涉及到高价值商品或用户高质量互动时。因此,公式引入了交互金额 m_{ij}^r 的对数修正项 $1 + \log(m_{ij}^r)$,这一部分旨在非线性放大高金额交易的影响力。通过对金额取对数,公式可以在一定程度上缓和金额增长的影响,但又不会完全忽略高金额交互的特殊意义。这种设计使得权重计算既考虑了用户行为的广泛性(频次),又关注了用户行为的深度和价值(金额),从而能够更加

精准地反映用户对产品的真实兴趣和偏好。

[0061] 另外,时间因素 t_{ij}^r 的引入体现了系统对用户行为动态性的关注。在现实场景中,用户行为的影响力会随着时间的推移而逐渐衰减。为此,公式中加入了一个时间衰减因子 λ 和一个指数函数 $\exp(-\lambda \cdot t_{ij}^r)$,该部分用于模拟行为影响的时间衰减效应。衰减因子 λ 控制了时间对权重的影响程度,当 λ 较大时,权重会快速衰减,反之亦然。这种设计考虑了用户行为的时效性,即越是近期的行为对用户当前偏好的影响越大,而较早前的行为对当前决策的参考价值会降低。通过这种方式,系统能够动态调整权重计算,确保推荐结果更符合用户当前的兴趣和需求。此外,用户产品评价指数 R_{ij} 的加入进一步增强了权重计算的准确性。该指数反映了用户对产品的主观满意度或喜好程度,这是用户在消费过程中留下的重要反馈信息。通过将评价指数与权重计算相乘,系统能够在一定程度上体现用户的情感和态度。正面的评价会增加权重,从而提高产品被推荐的可能性,而负面的评价则会降低权重,减少推荐的机会。这样,系统不仅依赖于客观的行为数据,还结合了用户的主观反馈,使得推荐结果更加个性化和人性化。公式中的分母部分则起到了归一化的作用,它将所有可能的用户-产品交互的权重进行标准化处理,以确保计算的权重在不同的用户和产品之间具有可比性。这种归一化处理避免了由于个别用户或产品的极端行为(例如高频次或高金额的极端交易)而导致的权重失真,从而使得整个图模型更加稳健和公正。通过整合这些多维度的因素,权重公式实现了对用户-产品关系的多角度刻画,能够全面反映用户在不同行为类型下的复杂互动模式。最终,这些加权边集 E_r 的合并形成了一个完整的多维产品与关系图 $G = (V, E)$,其中的每一条边都代表了用户与产品之间的某种关系及其强度。这种多关系图不仅仅是用户与产品交互数据的简单汇总,它在结构上体现了用户行为的多样性和复杂性,为后续的智能分析和策略制定提供了丰富的语义信息。

[0062] 实施例5:特征提取单元首先使用 L 层的卷积神经网络提取多维产品与关系图的特征,公式如下:

$$H^{(l+1)} = \sigma \left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W + \alpha \cdot \text{ReLU}(\text{BatchNorm}(H^{(l)})) + \beta \cdot \text{GRU}(H^{(l)}, H^{(l-1)}) \right) ;$$

[0064] 其中,GRU是门控循环单元; $H^{(l)}$ 是第 l 层的节点特征矩阵; $H^{(l+1)}$ 是第 $l+1$ 层的节点特征矩阵; σ 是非线性激活函数; $\tilde{A} = A + I_N$ 是添加了自连接 I_N 的邻接矩阵; A 为邻接矩阵; $\tilde{D}$ 是 $\tilde{A}$ 的度矩阵; W 是权重矩阵,其中第 i 行,第 j 列的元素为 $w_{i,j}$;BatchNorm是批量归一化操作; α 和 β 均分别是预设的平衡不同组件贡献的超参数;最终的特征提取结果是最后

一层的输出 $H^{(l)}$ ；设定产品权重为 C ，对于第 $l+1$ 层的节点特征矩阵 $H^{(l+1)} = (1 - C)H_U^{(l+1)} + CH_P^{(l+1)}$ ； $H_U^{(l+1)}$ 、 $H_P^{(l+1)}$ 分别是第 $l+1$ 层的用户节点特征矩阵和产品节点特征矩阵。

[0065] 具体的，特征提取的关键在于多层图卷积网络的设计，它能够在每一层卷积操作中聚合节点及其邻居节点的信息，逐层挖掘图的局部和全局结构特征。首先，卷积神经网络的核心公式中，节点特征矩阵 $H^{(l)}$ 的更新过程基于归一化的邻接矩阵 $\tilde{A} = A + I_N$ 和度矩阵 $\tilde{D}$ 的相互作用。这种设计引入了图的结构信息，其中 $\tilde{A}$ 不仅包含了原始图的连接关系，还加上了自连接矩阵 I_N ，确保每个节点在每层卷积中不仅整合了邻居节点的信息，还保留了自身的特征信息。自连接的加入是为了防止信息在多层卷积中被过度平滑化，使得节点特征仍然能够保持一定的个性和区分度，这对于捕捉用户和产品的独特行为模式尤为重要。在特征更新过程中，权重矩阵 W 用于学习特征的线性变换，这些权重通过训练过程不断优化，以最小化特定的目标函数（例如预测误差）。这一过程使得卷积神经网络能够在节点特征空间中学习到最具辨识度的特征组合，从而提升系统对用户偏好和产品相关性的识别能力。这些特征的优化和学习，不仅考虑了用户的直接交互行为，还通过图结构捕捉到了用户之间的潜在影响和产品之间的相互关联，使得系统能够在更高的维度上理解市场行为。公式中还引入了批量归一化 (BatchNorm) 和非线性激活函数（如ReLU）的组合，这些都是深度学习网络中提升模型性能和稳定性的关键技术。批量归一化通过对每一层的输出进行标准化处理，消除不同输入批次之间的分布差异，从而加速模型训练并提高泛化能力。激活函数 σ 的引入，则赋予了模型非线性拟合能力，使得其能够处理更加复杂的模式和数据分布。在特征提取过程中，这种非线性转换能够有效增强模型的表达能力，捕捉到更为细微的用户与产品之间的互动特征，这对于精准的用户行为预测和产品推荐是至关重要的。进一步增强模型复杂性和表达能力的是门控循环单元 (GRU) 的集成。GRU 作为一种简化的递归神经网络结构，能够高效地处理序列数据中的长短期依赖关系。在本发明的特征提取单元中，GRU 的引入使得系统能够捕捉用户行为和产品互动的动态性。通过结合当前层和前一层的节点特征，GRU 可以记忆用户行为的历史模式，并根据这些模式预测未来行为。GRU 的门机制允许网络自动调节信息的流动，这对于处理复杂的用户行为序列数据尤其有用。通过这一机制，系统不仅可以捕捉用户的短期行为偏好，还可以识别用户长期的消费习惯和兴趣变化，使得推荐结果更加符合用户的实际需求和市场趋势。此外，特征提取单元中对于用户节点和产品节点的差异化处理进一步提高了系统的灵活性和适应性。通过引入产品权重 C ，系统能够在特征提取过程中调整用户特征和产品特征的相对重要性。这一权重的调整是基于不同的应用场景和营销需求而设定的。例如，在某些情境下，用户的行为特征可能更为关键，因此可以降低产品特征的权重 C ，反之亦然。这种权重调节机制确保了系统能够在不同的市场环境和营销策略下灵活应用，最大化地利用数据中的信息，提高推荐和营销的效果。公式的最终输出是经过多层卷积和非线性变换后的节点特征矩阵 $H^{(L)}$ ，这个矩阵集成了所

有L层的特征信息,形成了一个高度凝练的特征表示,涵盖了用户与产品之间的多维度互动信息。通过这种高维特征表示,智能化营销系统能够在复杂的市场环境中更准确地定位用户需求,优化产品推荐策略,并最终提高用户的消费频次和规模。系统的这种特征提取能力,不仅提升了推荐算法的准确性和精度,还显著改善了用户体验,增强了用户的粘性和参与度。

[0066] 实施例6:多关系图卷积模型分析单元的执行过程具体包括:根据特征提取单元的输出结果,初始化用户节点特征矩阵 $H_U \in \mathbb{R}^{N \times d}$ 和产品节点特征矩阵 $H_P \in \mathbb{R}^{M \times d}$,其中 N 是用户数量, M 是产品数量, d 是特征维度;对于每种关系类型 $r \in \{1, 2, \dots, 5\}$,构建一个图卷积层,每层的更新规则如下:

$$[0067] \quad H_U^{(l+1)} = \sigma \left(\sum_{r=1}^5 \tilde{D}_r^{-\frac{1}{2}} \tilde{A}_r \tilde{D}_r^{-\frac{1}{2}} H_U^{(l)} W_r + \text{GRU}(H_U^{(l)}, H_U^{(l-1)}) \right);$$

$$[0068] \quad H_P^{(l+1)} = \sigma \left(\sum_{r=1}^5 \tilde{D}_r^{-\frac{1}{2}} \tilde{A}_r^T \tilde{D}_r^{-\frac{1}{2}} H_P^{(l)} W_r + \text{GRU}(H_P^{(l)}, H_P^{(l-1)}) \right);$$

[0069] 其中: $\tilde{A}_r$ 是第 r 种交互类型的邻接矩阵加上自连接; $\tilde{D}_r$ 是 $\tilde{A}_r$ 的度矩阵;

$W_r = \sum_{i=1}^N \sum_{j=1}^M w_{i,j,r}$;得到最终的图卷积层的输出为 $H_U^{(L)}$ 和 $H_P^{(L)}$;引入关系级别的注意力机制,计算每种交互类型的重要性 e_r ;根据每种关系的重要性 e_r ,使用多头注意力机制聚合不同交互类型的表示,得到多头注意力结果;对每个多头注意力结果进行归一化操作,分别得到用户的最终嵌入表示 $E_U \in \mathbb{R}^{N \times d}$,以及产品的最终嵌入表示 E_P ; $\mathbb{R}$ 表示实数域。

[0070] 具体的,该单元从特征提取单元获得初始的用户节点特征矩阵 H_U 和产品节点特征矩阵 H_P ,每个特征矩阵分别代表了用户和产品在高维空间中的表示。这些初始特征为后续的图卷积操作提供了基本的输入,使得系统可以通过进一步的计算,逐层挖掘和提炼用户与产品之间更深层次的关系。在图卷积操作中,每一层的用户特征和产品特征都通过邻接矩阵 $\tilde{A}_r$ 和度矩阵 $\tilde{D}_r$ 进行更新。这些矩阵的作用在于捕捉用户和产品节点之间的结构化信息,特别是在多种不同关系类型的交互背景下。例如,用户可能在系统中与多个产品存在购买、浏览、评论等不同类型的交互,每一种交互都能为节点提供不同的特征信息。在每一层卷积中,通过对邻接矩阵进行归一化处理,系统能够确保信息在节点间的传播保持均衡,避免因为某些节点的高连接度而导致的特征过度集中。这种归一化操作有助于保持特征的多样性,使得每个节点的特征更新既考虑了自身的特性,也受到了其邻居节点的影响。门控循环单元(GRU)的引入是该公式中的另一关键部分。GRU本质上是一种递归神经网络,它通过引入门机制来控制信息的流动和记忆,这对于处理时间序列数据特别有效。在本发明的情境下,用户的行为是动态的,可能随时间发生变化。因此,GRU通过结合当前层和前一层的特征,可以捕捉到用户行为和产品互动的动态性。这种时间维度的考虑使得模型能够

更准确地反映用户的实际消费模式,进而提高推荐的准确性。例如,如果用户在近期对某一类产品表现出了较高的兴趣,那么GRU可以在特征更新中增加这一信息的权重,从而让系统更倾向于推荐相关产品。

[0071] 在图卷积过程中,用户节点特征和产品节点特征是通过多层次的卷积逐步提取的。随着卷积层数的增加,系统能够从更广泛的图结构中提取信息,使得节点的最终特征表达更加全面和丰富。每一层的卷积操作不仅整合了当前节点的特征,还结合了邻居节点的特征,并通过GRU机制考虑了历史信息的影响。这种多层卷积和递归机制的结合,使得系统能够捕捉到更复杂的用户-产品关系和行为模式,为后续的决策提供更有力的数据支持。此外,为了进一步提高模型的表达能力和精度,系统引入了关系级别的注意力机制。这一机制的作用在于对不同关系类型的重要性进行评估和加权。在实际应用中,不同的用户行为对营销策略的影响可能不同,例如购买行为通常比浏览行为更能直接反映用户的消费意图。通过计算每种关系类型的重要性权重 e_r ,系统能够识别出哪些关系对当前的营销目标最为关键。随后,多头注意力机制会将这些权重应用于不同的关系类型上,聚合这些关系类型的特征表示,生成最终的节点嵌入表示。这种多头注意力机制不仅允许模型在特征提取时考虑多个关系类型的异质性,还能够通过归一化操作确保各关系类型在最终特征表示中的贡献是均衡和合理的。最终,用户和产品的嵌入表示 E_U 和 E_P 作为模型的输出,它们代表了用户和产品在高维空间中的位置和特征。通过这些嵌入表示,系统可以进一步进行个性化推荐、用户画像构建以及营销策略的优化。

[0072] 实施例7:通过如下公式,计算每种交互类型的重要性 e_r :

$$[0073] \quad e_r = \frac{\exp(\tanh(X(F_{collect}(U,P)) \cdot [H_U^{(L)} || H_P^{(L)}]))}{\sum_{r=1}^5 \exp(X(F_{collect}(U,P)) \cdot \tanh[H_U^{(L)} || H_P^{(L)}])};$$

[0074] 其中, $||$ 表示拼接操作; $X(\cdot)$ 为求矩阵的秩的运算。

[0075] 具体的,在实施例7中,多关系图卷积模型分析单元通过计算每种交互类型的重要性 e_r ,为智能化营销系统提供了一个深度理解用户与产品之间多维交互的机制。这个公式的核心在于使用非线性函数和矩阵操作,来衡量和比较不同交互类型对用户消费行为的相对贡献。通过计算这些权重,系统能够更精准地聚焦于最能影响用户行为的交互类型,从而优化推荐策略,提升营销效果,实现扩大消费频次和消费规模的目标。公式的设计使用了一个非线性激活函数 $\tanh(\cdot)$,这一函数在本公式中用于将特征空间中的值映射到一个介于-1和1之间的范围内。激活函数的作用是对输入特征进行非线性转换,使得特征的分布更加均匀,有助于模型在学习过程中更好地捕捉复杂的关系模式。在公式中, $\tanh$ 函数的输入是一个由特征提取结果 $H_U^{(L)}$ 和 $H_P^{(L)}$ 拼接而成的矩阵,这个拼接操作($||$)将用户特征和产品特征合并在一起,从而形成一个综合的特征表示。接下来,公式引入了一个求矩阵秩的运算 $X(F_{collect}(U,P))$,这个运算用于衡量从数据采集过程 $F_{collect}(U,P)$ 中获得的用户和产品的交互数据的复杂性。矩阵的秩表示了线性独立的行或列的数量,反映了矩阵的维度

和信息量。在这个背景下,秩的计算帮助系统理解交互数据的多样性和复杂性。例如,如果一个交互类型在数据中出现的频次较高且分布较为均匀,那么其秩值较高,意味着该交互类型提供了更多的信息。通过将秩与特征矩阵相乘,系统可以放大或缩小不同特征的影响力,从而对每种交互类型的重要性进行细微的调整。接着,公式使用了一个指数函数 $\exp(\cdot)$ 来进一步提升这些加权特征的相对差异。指数函数的使用在这里有双重意义:首先,它将所有的特征值转化为正数,确保最终计算出的权重是非负的,这对于概率分布的计算是必要的;其次,指数函数具有放大较大输入值的作用,从而能够突出那些对用户行为影响更大的交互类型。通过这种放大效应,系统可以更敏锐地识别出关键的用户行为模式和产品特征。最后,公式的归一化操作通过对每种交互类型的指数结果进行求和,确保所有交互类型的重要性权重之和为1。这种归一化过程是必要的,因为它将每个交互类型的重要性转化为一个概率分布,使得这些权重具有直观的解释力:一个较大的权重 e_r 表示该交互类型对用户行为预测和产品推荐更为重要。通过这种方式,系统能够动态地调整对不同交互类型的关注度,从而在个性化推荐和营销策略制定中,优先考虑那些对用户决策最有影响的行为模式。

[0076] 实施例8:通过如下公式,使用多头注意力机制聚合不同交互类型的表示,得到多头注意力结果:

$$[0077] \quad Z_U = \text{MultiHead}(H_U^{(L)}, H_P^{(L)}, H_P^{(L)});$$

$$[0078] \quad Z_P = \text{MultiHead}(H_P^{(L)}, H_U^{(L)}, H_U^{(L)});$$

[0079] 其中, Z_U 为用户的多头注意力结果; Z_P 为产品的多头注意力结果; $\text{MultiHead}()$ 函数定义为:

$$[0080] \quad \text{MultiHead}() = \text{Concat}(\text{head}_1, \dots, \text{head}_h) W^O;$$

$$[0081] \quad \text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V);$$

$$[0082] \quad \text{Attention}() = \text{softmax}\left(\frac{QK^T}{\sqrt{d}}\right)V;$$

[0083] 其中, h 为注意力头的数量; W^O 为多头注意力输出的线性变换矩阵; $\text{Attention}()$ 为注意力计算函数, 计算查询和键之间的相似度, 并用于加权值矩阵; K 为键矩阵; V 为值矩阵; Q 为查询矩阵; head_i 为第 i 个注意力头的输出; W_i 为第 i 个注意力头的线性变换矩阵; $\text{softmax}()$ 为 softmax 函数; T 为矩阵的转置运算。

[0084] 具体的, 公式中的多头注意力机制通过函数 $\text{MultiHead}(\cdot)$ 聚合不同交互类型的表示, 得到用户和产品的多头注意力结果 Z_U 和 Z_P 。这些结果是对用户节点特征 $H_U^{(L)}$ 和产品

节点特征 $H_P^{(L)}$ 的多重关系表示的综合分析。多头注意力机制的核心思想在于通过多个注意力头来捕捉数据的多样性和复杂性,每个注意力头独立地学习数据中的某一特定模式或关系,然后通过将这些模式组合起来,生成一个更为全面和准确的特征表示。在多头注意力机制中,函数 $\text{MultiHead}(\cdot)$ 先将多个注意力头的输出 head_i 进行拼接(Concat),然后通过一个线性变换矩阵 W^O 进行转换。每个注意力头的输出 head_i 是通过注意力计算函数 $\text{Attention}(\cdot)$ 得到的。注意力计算函数的原理是基于查询矩阵 Q 、键矩阵 K 和值矩阵 V 之间的相似度来进行加权计算。在公式中,通过对 Q 和 K 的乘积进行归一化(除以 $\sqrt{d}$,其中 d 是特征维度)并应用 $\text{softmax}(\cdot)$ 函数,计算出查询和键之间的注意力权重。这些权重反映了不同特征之间的相对重要性,并被用来加权值矩阵 V 中的特征。通过这种方式,多头注意力机制可以同时关注数据的多个方面,从而有效捕捉用户和产品之间的多种复杂关系。例如,一个注意力头可能重点关注用户的购买行为,而另一个注意力头则可能更关注用户的浏览历史或产品评价。通过同时考虑这些不同的交互类型,系统能够更全面地理解用户的兴趣和偏好,并相应地调整推荐策略和营销活动。多头注意力机制的另一大优势在于它能够提高模型的稳健性和泛化能力。由于每个注意力头独立工作并关注数据的不同方面,它们的组合使得最终的特征表示更加丰富和多样化,减少了对单一特征或模式的依赖。这种特性尤其适用于智能化营销系统,因为它能够处理大量用户和产品数据中的噪声和异常情况,确保推荐结果的准确性和可靠性。在实际应用中,用户的多头注意力结果 $Z_U = \text{MultiHead}(H_U^{(L)}, H_P^{(L)}, H_P^{(L)})$ 和产品的多头注意力结果

$Z_P = \text{MultiHead}(H_P^{(L)}, H_U^{(L)}, H_U^{(L)})$ 提供了深度学习模型在用户和产品特征表示上的高效聚合和优化。通过分别将用户特征和产品特征作为查询矩阵 Q 、键矩阵 K 和值矩阵 V ,系统能够有效计算和利用这些特征之间的复杂交互关系,从而提高推荐结果的相关性和用户体验。最终,注意力计算结果通过线性变换和拼接操作,整合了多个注意力头的输出,形成了丰富的多维度特征表示。这些表示不仅包括了用户和产品的直接关系,还涵盖了它们之间的间接联系和潜在模式。通过这种深度特征学习和表示,多头注意力机制为智能化营销系统提供了强大的分析和预测能力,使得系统能够更加精准地进行个性化推荐和营销策略优化,最终实现扩大消费频次和规模的目标。

[0085] 实施例9:所述促销策略生成单元,根据用户的嵌入表示和产品的嵌入表示,通过如下公式,计算每个用户和产品的匹配度 MO :

$$[0086] \quad MO = \frac{E_U^T E_P}{\|E_U\| \|E_P\|} + \exp\left(-\lambda \cdot \frac{t_{\text{current}} - t_{ij}^r}{\max(N, t_{ij}^r)}\right) + \frac{1}{1 + \exp(1 - (\sum_{r=1}^5 \|W_r\|))};$$

[0087] 其中, t_{current} 为当前时间; t_{ij}^r 为用户 i 到产品 j 最后一次进行用户行为类型 r 的交

互距今的时间; $\|\cdot\|$ 为求向量的模的运算。

[0088] 具体的,公式的第一部分 $\frac{E_U^T E_P}{\|E_U\| \|E_P\|}$ 是经典的余弦相似度计算方法,用于度量用户嵌

入表示 E_U 和产品嵌入表示 E_P 之间的相似性。余弦相似度的取值范围在-1到1之间,值越接近1表示用户与产品之间的匹配度越高。在智能化营销系统中,用户和产品的嵌入表示是通过多层卷积网络和多头注意力机制从复杂的多关系图中提取出来的,包含了用户行为和产品特征的深度信息。因此,余弦相似度能够有效捕捉用户和产品之间的潜在关系,并将其用于推荐决策。这部分的计算确保了推荐系统优先考虑那些与用户兴趣和需求高度匹配的产品。

公式的第二部分 $\exp\left(-\lambda \cdot \frac{t_{\text{current}} - t_{ij}^r}{\max(N, t_{ij}^r)}\right)$ 引入了时间衰减因素,用于衡量用户行为的时

效性对匹配度的影响。这里, t_{current} 是当前时间, t_{ij}^r 是用户 i 对产品 j 最后一次进行行为类型 r 的交互时间。时间衰减因子 λ 控制了用户行为影响的衰减速度。这个设计体现了一个重要的营销策略原则:用户的最新行为比过去的行为更能反映当前的兴趣和需求。因此,越是近期的用户行为对匹配度的贡献越大,而随着时间的推移,行为的影响力会逐渐减弱。通过这种方式,系统能够更动态地调整推荐策略,使其更贴近用户的当前需求和市场环境。公式

的第三部分 $\frac{1}{1 + \exp\left(1 - (\sum_{r=1}^5 \|W_r\|)\right)}$ 是一个基于行为多样性的修正项。这一部分利用了用户在

不同交互类型(如购买、浏览、评论等)上的行为权重 W_r 的范数总和来调整匹配度。这种设计的目的是考虑用户在多种行为类型下的全面表现。如果用户在多个行为类型中都有高频次和高权重的交互,这表明用户对产品有多方面的兴趣和高互动性,因此匹配度会被适当地提高。反之,如果用户的行为集中在某一类型且缺乏多样性,这可能意味着用户的兴趣有限或者行为数据不足,匹配度会被相应地调整降低。这种匹配度计算方法体现了智能化营销系统的多维度分析能力,不仅考虑了用户和产品之间的特征相似性,还结合了时间因素和行为多样性,确保推荐的结果更加精准和个性化。通过引入时间衰减和行为多样性修正,系统能够有效应对用户兴趣变化和行为模式的复杂性,保持对用户需求的敏感性和响应速度。

[0089] 虽然以上描述了本发明的具体实施方式,但是本领域的技术人员应当理解,这些具体实施方式仅是举例说明,本领域的技术人员在不脱离本发明的原理和实质的情况下,可以对上述方法和系统的细节进行各种省略、替换和改变。例如,合并上述方法步骤,从而按照实质相同的方法执行实质相同的功能以实现实质相同的结果则属于本发明的范围。因此,本发明的范围仅由所附权利要求书限定。




图1