

doi:10.19920/j.cnki.jmsc.2025.02.008

基于信任度与遗忘函数的个性化产品服务配置^①

窦润亮¹, 孟繁松¹, 南国芳¹, 周晓东¹, 林国义^{2,3}

(1. 天津大学管理与经济学部, 天津 300072; 2. 同济大学电子与信息工程学院, 上海 201804;
3. 同济大学上海智能科学与技术研究院, 上海 201804)

摘要: 在客户需求个性化和多样化的趋势下,企业面临着如何快速响应客户需求并提供个性化产品服务方案的挑战。为帮助客户精准定位个性化产品服务方案,提出了一种基于信任度与遗忘函数的个性化产品服务配置方法,分别在偏好相似度和评分相似度计算中引入信任度和时间遗忘权重,同时综合考虑用户和方案的组合相似度,以降低数据稀疏性和冷启动在预测个性化方案时的影响。通过与现有方法进行比较,本研究提出的方法能为用户更加精准地配置出符合其需求的个性化产品服务方案。

关键词: 产品服务方案; 信任度; 遗忘函数; 协同过滤

中图分类号: TP391.3; F273.2 文献标识码: A 文章编号: 1007-9807(2025)02-0102-13

0 引言

《中国制造 2025》指出制造企业要优先发展服务型制造,不仅要关注产品的生产,还要关注产品价值的实现。通过从仅提供“产品”向提供物品、支持、服务、知识的“产品-服务包”的转变,企业的竞争优势得以提升,因此制造业服务化逐渐成为制造企业转型升级的主要方向^[1]。有学者提出了产品服务系统(product service system, PSS)的概念,将其定义为以用户需求为中心,整合产品、服务、基础设施等要素,向客户提供个性化产品服务方案的价值系统^[2],针对 PSS 的研究也逐渐成为学术界和产业界的热点。同时,随着社会信息化的发展以及顾客偏好异质性的变化,用户需求变得更为复杂和细化,因此,如何根据用户需求提供个性化 PSS 方案成为制造企业面临的主要挑战^[3]。部分学者对 PSS 的模块化设计进行了研究,包括配置设计、数据建模、模块划分等^[4],通过对用户需求进行个性

化分析,进而对 PSS 方案进行配置。然而随着用户需求的不断变化,单纯的模块化设计难以满足用户一对一的个性化需求^[5]。因此,有学者在 PSS 中引入协同过滤技术,根据消费者的个性化需求向其提供个性化 PSS 方案,以增加顾客的满意度和忠诚度^[6]。

本研究在传统协同过滤方法的基础上进行了改进,提出了基于信任度与遗忘函数的个性化产品服务配置方法。首先,根据历史数据分别计算用户间与方案间的偏好相似度和评分相似度。其次,充分考虑信任度对用户间和方案间相互关系的影响,以及时间对用户兴趣的影响,分别在偏好相似度计算和评分相似度计算中引入信任权重和时间权重,并将用户间与方案间的偏好相似度和评分相似度进行组合,以搜索具有最高相似度的近邻。最后,利用最近邻集为目标用户进行方案的评分预测,并根据预测结果为用户提供最优方案。

① 收稿日期: 2021-01-18; 修订日期: 2022-01-20。

基金项目: 国家社会科学基金资助项目(18BGL095); 国家自然科学基金委员会重大研究计划资助重点项目(92167206); 国家自然科学基金资助项目(72471168)。

作者简介: 窦润亮(1977—),男,天津人,博士,教授,博士生导师。Email: drl@tju.edu.cn

1 相关工作

近年来,有关提供个性化 PSS 方案的相关研究已有很多,大部分研究是围绕着以满足顾客需求、实现客户满意度最大化为目标进行的模块化设计,如 Chen^[7] 和 Fadeyi^[8] 分别采用模糊数据包络分析法、多目标规划法进行了 PSS 方案设计。然而多数文献在研究最优 PSS 方案时没有考虑用户需求多样性的特点,因此一些学者将协同过滤技术引入 PSS 中。陈耶拉等^[9] 对协同过滤方法进行改进,通过在 BP 神经网络中引入各方案的属性权重,为用户提供个性化 PSS 方案。杨珍等^[10] 利用加权隐语义模型构建了面向个性化产品服务系统方案的匹配方法。Song 等^[11] 考虑了 PSS 方案的环境因素,提出了模糊环境下基于粗糙协同过滤的 PSS 方案配置方法。这些个性化配置方法虽然在一定程度上满足了 PSS 方案与用户需求的精准匹配,但大多数方法仅考虑了方案的特征属性,未考虑用户的需求变化,忽视了 PSS 中用户间的相互关系。因此本研究在研究个性化产品服务配置方法时,充分考虑了方案间与用户间的相互关系。

在以往应用协同过滤技术进行 PSS 方案匹配时,多是在基于用户协同过滤方法的基础上进行的改进。基于用户的协同过滤虽然可以有效地利用用户间的相互关系和其他用户的反馈信息对用户进行排序分类,得到较为精准的推荐结果,但通常存在冷启动和数据稀疏性两个问题。因此,部分学者开始借助地理位置信息^[12]、人口统计信息^[13](性别、年龄等)、消费者情绪^[14]、社交网络^[15]等来解决上述两个问题,但大多是从用户的角度对协同过滤方法进行改进,缺乏对方案相似度计算过程的考虑。基于方案的协同过滤根据方案间的相似性为用户生成推荐列表。Seng 等^[16] 指出方案数通常远小于用户数,且方案的数量和相似度相对比较稳定,在这种情况下基于方案的机制比基于用户的机制具有更好的推荐效果。但是,若仅仅采用基于方案的协同过滤方法或基于用户的协同过滤方法,会忽视另一个群体的影响作用,

导致推荐不够全面。因此,同时考虑用户间、方案间的相似性进行评分预测,可以综合二者的优势,进一步提高推荐的精度,保证推荐的稳定^[17]。Zhang 等^[18] 则从用户与服务两个视角同时进行研究,将社会网络与协同过滤方法相结合,以用户与服务为节点构建社会网络,分别计算用户间和服务间的偏好、标记、评级相似度,从而缓解数据稀疏性和冷启动问题。但此方法忽略了时间变化对用户兴趣的影响,不能有效地实现动态分析。借鉴上述解决冷启动与数据稀疏性的方法,综合考虑用户与方案两个维度,提出了基于信任度与遗忘函数的个性化产品服务配置方法。

有研究表明,相较于系统的提示,用户更倾向于接受熟人的建议^[19],用户间的偏好相似度和用户的信任度之间存在着正相关关系^[20]。在偏好相似度计算中融入用户信任关系,一方面可以提高推荐的准确率^[21],另一方面可以借助信任的传递性为目标用户匹配更大的邻居集,从而更好地缓解数据稀疏性问题^[22]。Lai 等^[23] 将相似度与信任度相结合,提出了基于信任关系的社交网络产品推荐方法。Guo 等^[24] 通过在用户相似度中引入信任机制来提高预测的准确性。其中,信任机制是通过挖掘用户对项目的评分而获得的用户之间的关联关系。上述文献虽然通过引入信任机制来捕捉用户的兴趣偏好,但仅考虑了信任机制对用户的影响,忽略了对方案间相似程度的深入挖掘。因此本研究进一步考虑了系统的内在关系,在用户间和方案间的偏好相似性计算中均引入了信任模型。

用户的兴趣会随着时间发生变化,因此部分研究在计算相似度时考虑了时间因素的影响。罗园等^[25] 将时间权重分别引入标签相似度和评分相似度计算中,构建了基于时间的相似度计算方法。Chen 等^[26] 提出了基于用户兴趣动态变化的推荐算法,通过构建时间衰减函数调整原始评分矩阵,以减弱用户早期评分的贡献值,增强近期评分的贡献值。可见,通过对评分数据赋予不同的权重可以模拟用户兴趣的变化,更加准确地计算不同用户间的兴趣相似性。同理,方案间的相似度也

可以通过引入时间权重进行修正,当两个方案在相近的时间范围内被同一用户所使用,则可以推断这两个方案有较大的关联。但上述文献均只在用户相似度计算中考虑了时间因素,未将时间权重引入方案相似度计算中。基于上述文献的启发,本研究将非线性逐步遗忘函数分别引入用户相似性和方案相似性计算模型中。

本研究综合考虑上述文献中的问题,提出了基于信任度与遗忘函数的个性化产品服务配置方法,分别在偏好相似度和评分相似度的计算中引入信任关系和时间权重。同时将偏好相似度与评分相似度的计算划分为用户和方案两个维度,并将两种相似度进行组合,通过组合相似度进行评分预测及方案匹配,极大缓解了冷启动与数据稀疏的问题。

2 基于信任度与遗忘函数的个性化配置过程

本研究提出个性化产品服务配置方法的配置过程如图 1 所示,相关符号说明如表 1 所示。首先在历史偏好数据中加入对信任度的考量,在历史评分数据中加入时间遗忘权重,分别计算用户间和方案间的偏好相似度、评分相似度。然后将用户间的偏好相似度与评分相似度结合,将方案间的偏好相似度与评分相似度结合,分别形成用户间的组合相似度与方案间的组合相似度。最后利用组合相似度预测目标用户对 PSS 方案的评分,并通过预测值为目标用户推荐前 N 个方案,完成整个个性化方案配置过程。

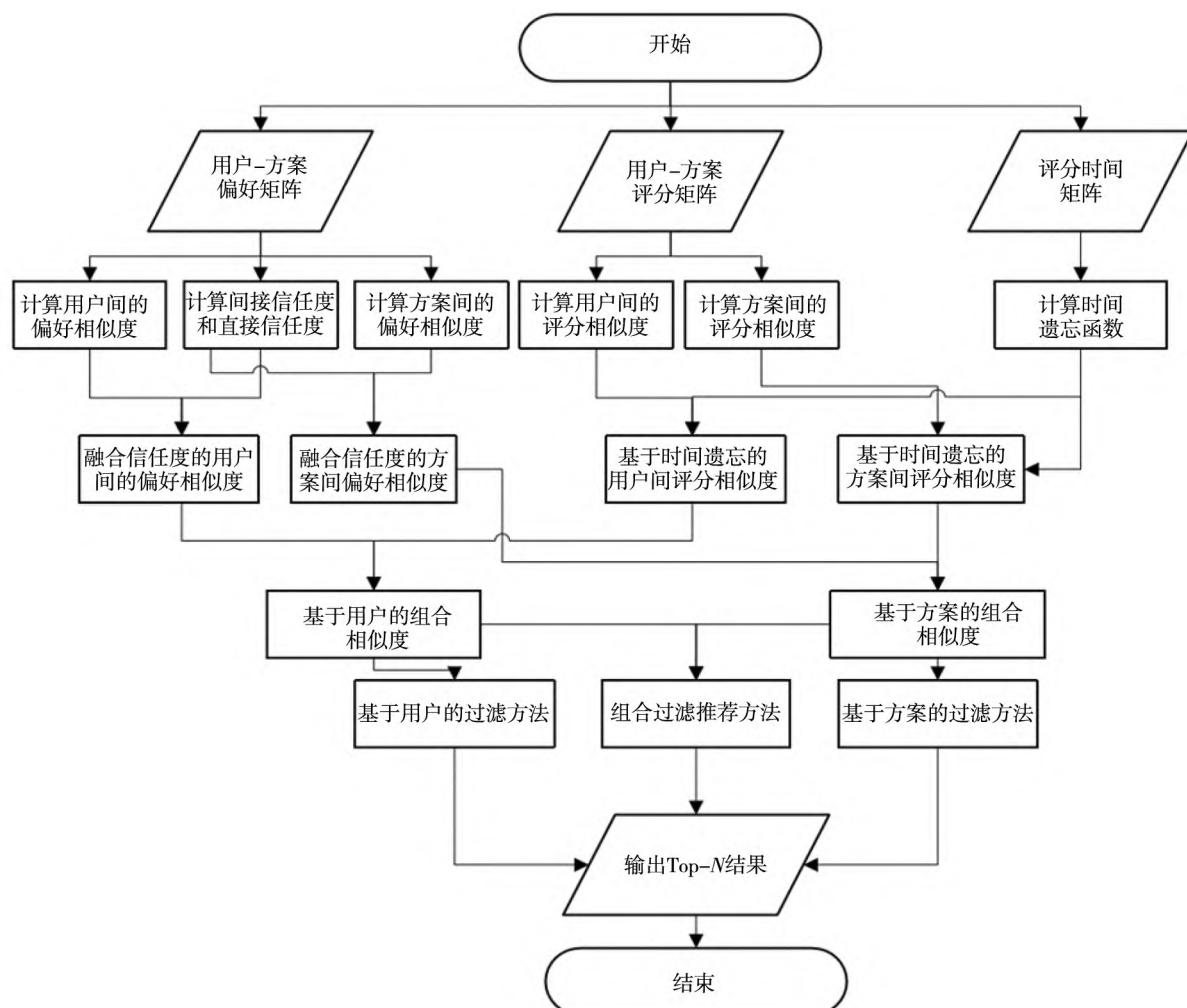


图 1 个性化产品服务配置流程

Fig. 1 Personalized product service configuration process

表1 符号说明

Table 1 Parameter definition

符号	含义
m	用户数
n	方案数
U_i	用户 i
S_j	方案 j
$E_{m \times n}$	用户 - 方案偏好矩阵
$W_{m \times n}$	用户 - 方案评分矩阵
e_{ij}	用户 i 使用方案 j 的次数
w_{ij}	用户 i 对方案 j 的评分
p_1	两个用户间共同使用过的方案数
q_1	同时使用某两个方案的用户数
p_2	两个用户共同评分的方案数
q_2	对某两个方案共同评分的用户数
\bar{e}_i	用户 i 使用所有方案的平均次数
\bar{e}_{S_j}	方案 j 被所有用户使用的平均次数
\bar{w}_i	用户 i 对所有方案的平均评分
\bar{w}_{S_j}	方案 j 被所有用户评分的平均评分
$ I_i $	用户 i 使用过的方案数量
$ I_{i,j} $	用户 i 和用户 j 共同使用过的方案数量
$ J_i $	方案 i 被使用过的次数
$ J_{i,j} $	方案 i 和方案 j 被共同使用过的次数
K	用户的近邻数 K
L	方案的近邻数 L

2.1 基于信任度的偏好相似度计算

传统的偏好相似度是通过用户对方案的偏好程度来计算的, 每个用户的偏好可以利用用户对某方案的使用次数表示. 给定一个 $m \times n$ 的用户 - 方案偏好矩阵 $E_{m \times n}$, 矩阵 $E_{m \times n}$ 的每一项 e_{ij} 表示用户 U_i 使用方案 S_j 的次数, 若用户 U_i 未使用过 PSS 方案 S_j , 则 $e_{ij} = 0$, 如表 2 所示.

表2 用户 - 方案偏好矩阵

Table 2 User-scheme preference matrix

用户	方案 S_1	方案 S_2	...	方案 S_n
U_1	$e_{1,1}$	$e_{1,2}$...	$e_{1,n}$
U_2	$e_{2,1}$	$e_{2,2}$...	$e_{2,n}$
...
U_m	$e_{m,1}$	$e_{m,2}$...	$e_{m,n}$

基于用户 - 方案矩阵数据的相似性计算方法有余弦相似性、皮尔森系数法等^[27]. 相对于余弦相似性, 皮尔森系数对变量进行了均值化处理, 能够减少变量个体的数值差异对变量间相似度的影响, 因此本研究生使用皮尔森相关系数来计算偏好相似度. 用户 U_1 与 U_2 的偏好相似度计算公式如下

$$PSim(U_1, U_2) =$$

$$\frac{\sum_{i=1}^{p_1} (e_{1,i} - \bar{e}_1) \times (e_{2,i} - \bar{e}_2)}{\sqrt{\sum_{i=1}^{p_1} (e_{1,i} - \bar{e}_1)^2} \times \sqrt{\sum_{i=1}^{p_1} (e_{2,i} - \bar{e}_2)^2}} \quad (1)$$

$PSim(U_1, U_2)$ 的取值范围在 $[-1, 1]$ 之间, 值越大表示 U_1 和 U_2 越相关. 如果 $p_1 = 0$, 则 $PSim(U_1, U_2)$ 为空值.

同理, PSS 方案 S_1 与 S_2 之间的偏好相似度计算公式如下

$$PSim(S_1, S_2) =$$

$$\frac{\sum_{j=1}^{q_1} (e_{j,S_1} - \bar{e}_{S_1}) \times (e_{j,S_2} - \bar{e}_{S_2})}{\sqrt{\sum_{j=1}^{q_1} (e_{j,S_1} - \bar{e}_{S_1})^2} \times \sqrt{\sum_{j=1}^{q_2} (e_{j,S_2} - \bar{e}_{S_2})^2}} \quad (2)$$

$PSim(S_1, S_2)$ 的取值范围在 $[-1, 1]$ 之间, 值越大表示 S_1 和 S_2 越相关. 如果 $q_1 = 0$, 则 $PSim(S_1, S_2)$ 为空值.

在用户及方案偏好相似度计算之后, 本研究考虑了信任关系对其的影响. 信任通常包括显式信任和隐式信任, 显式信任需要从目标用户现存的社会关系获取信任值, 或者通过目标用户直接对其他用户的信任打分来形成信任关系, 具有操作不便等局限性. 而隐式信任则是通过用户间隐含的交互关系来推导信任值, 包括共同的方案评分、方案评论等, 从而建立用户之间的信任关系, 具有较强的适用性^[28]. 因此, 本研究采用隐式信任来衡量信任关系, 并将信任关系分为直接信任和间接信任. 当两个用户共同使用过某一方案时, 即可视为二者在该方案上存在一次交互行为, 可以建立直接信任关系. 定义 $TDir(U_a, U_b)$ 为用户 U_a 对 U_b 的直接信任度, 如图 2 所示.

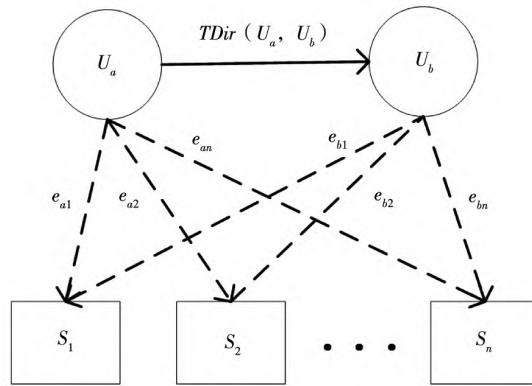


图2 直接信任关系

Fig. 2 Direct trust relationship

其中 S_1, S_2, \dots, S_n 表示用户 U_a 与 U_b 共同使用过方案集。传统偏好相似度是根据用户间共同使用过的方案来进行计算,因此可以用式(1)来衡量用户间交互行为,并假定相似度较高的用户间也具有较高的直接信任度。然而,式(1)忽略了方案数量影响,当数据稀疏时存在计算不准确的问题。例如,若用户 U_a 与 U_b 仅有 10 个共同使用过的方案,计算直接信任度为 0.9;而用户 U_a 与 U_c 有 100 个共同使用过的方案,计算的直接信任度为 0.8,显然 U_a 与 U_c 间的信任关系更可靠,因此在计算直接信任度时应该考虑共同使用过的方案数占总方案数的比例。Jaccard 相似度用于比较有限样本集之间的相似性,可以表示两个集合中交集与并集的比例关系,且值越大表示相关度越高。因此,本研究采用结合 Jaccard 相似度方式解决上述比例问题,用户 U_a 与 U_b 间的 Jaccard 相似度计算式如下

$$Jac(U_a, U_b) = \frac{|I_{a,b}|}{|I_a| + |I_b| - |I_{a,b}|} \quad (3)$$

则用户间直接信任度 $TDir(U_a, U_b)$ 的计算公式如下^[29]

$$TDir(U_a, U_b) = PSim(U_a, U_b) \times Jac(U_a, U_b) \quad (4)$$

两个用户之间的直接信任度取决于二者是否存在共同使用过的方案,而间接信任度则反映了信任具有传递的特点。如果用户 U_a 与 U_b 没有共同使用过的方案,则这两个用户之间不存在直接信任度,但二者有可能通过中间用户集 U_c 的传递存在间接信任度,因此仅采取直接信任度易导致对用户的描述不准确。同时,实际中用户间共同使用过的方案数据较少,增加间接信任度可以借助中间用户为目标用户获取更大的邻居集,填补空缺的相似数据,有效地缓解数据稀疏问题^[30]。用户 U_a 对 U_b 的间接信任度用 $TInd(U_a, U_b)$ 表示,间接信任关系如图 3 所示。

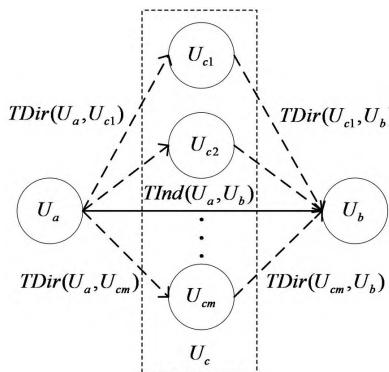


图 3 间接信任关系

Fig. 3 Indirect trust relationship

本研究假设两用户的间接信任关系只由一个中间用户传递,则用户间间接信任度的计算公式为

$$TInd(U_a, U_b) = \frac{\sum_{c \in U_c} TDir(U_a, U_c) \times TDir(U_c, U_b)}{|U_c|} \quad (5)$$

用户间的综合信任度计算公式为

$$T(U_a, U_b) = \phi TDir(U_a, U_b) + (1-\phi) TInd(U_a, U_b) \quad (6)$$

其中 $\phi \in (0,1)$, 表示直接信任度的重要程度, 值越大表示直接信任度对综合信任度的贡献越大。则融合了信任度的用户间偏好相似度计算公式为

$$T_P_Sim(U_a, U_b) =$$

$$\begin{cases} \frac{2T(U_a, U_b) \times PSim(U_a, U_b)}{T(U_a, U_b) + PSim(U_a, U_b)}, & T(U_a, U_b) > 0 \text{ 且 } PSim(U_a, U_b) > 0 \\ T(U_a, U_b), T(U_a, U_b) > 0 \text{ 且 } PSim(U_a, U_b) = 0 \\ 0, & T(U_a, U_b) = 0 \end{cases} \quad (7)$$

同理,融合了信任度的方案间偏好相似度计算公式为

$$T_P_Sim(S_1, S_2) =$$

$$\begin{cases} \frac{2T(S_1, S_2) \times PSim(S_1, S_2)}{T(S_1, S_2) + PSim(S_1, S_2)}, & T(S_1, S_2) > 0 \text{ 且 } PSim(S_1, S_2) > 0 \\ T(S_1, S_2), T(S_1, S_2) > 0 \text{ 且 } PSim(S_1, S_2) = 0 \\ 0, & T(S_1, S_2) = 0 \end{cases} \quad (8)$$

2.2 基于遗忘函数的评分相似度计算

传统评分相似度是通过用户的历史评分记录来反映用户间的兴趣相关程度。给定一个 $m \times n$ 的用户-方案评分矩阵,矩阵 $W_{m \times n}$ 的每一项 w_{ij} 表示用户 U_i 对 PSS 方案 S_j 的评分,若用户 U_i 未评分,则 w_{ij} 为空值,如表 3 所示。

表 3 用户-方案评分矩阵

Table 3 User-scheme rating matrix

用户	方案 S_1	方案 S_2	...	方案 S_n
U_1	$w_{1,1}$	$w_{1,2}$...	$w_{1,n}$
U_2	$w_{2,1}$	$w_{2,2}$...	$w_{2,n}$
...
U_m	$w_{m,1}$	$w_{m,2}$...	$w_{m,n}$

则用户间评分相似度计算公式如下

$$SSim(U_1, U_2) = \frac{\sum_{i=1}^{p^2} (w_{1i} - \bar{w}_1) \times (w_{2i} - \bar{w}_2)}{\sqrt{\sum_{i=1}^{p^2} (w_{1i} - \bar{w}_1)^2} \times \sqrt{\sum_{i=1}^{p^2} (w_{2i} - \bar{w}_2)^2}} \quad (9)$$

$SSim(U_1, U_2)$ 的取值范围在 $[-1, 1]$ 之间, 值越大表示 U_1 和 U_2 越相关. 如果 $p^2 = 0$, 则 $SSim(U_1, U_2)$ 为空值.

同理, PSS 方案间评分相似度计算公式如下

$$SSim(S_1, S_2) = \frac{\sum_{j=1}^{q^2} (w_{j1} - \bar{w}_{s_1}) \times (w_{j2} - \bar{w}_{s_2})}{\sqrt{\sum_{j=1}^{q^2} (w_{j1} - \bar{w}_{s_1})^2} \times \sqrt{\sum_{j=2}^{q^2} (w_{j2} - \bar{w}_{s_2})^2}} \quad (10)$$

$SSim(S_1, S_2)$ 的取值范围在 $[-1, 1]$ 之间, 值越大表示 S_1 和 S_2 越相关. 如果 $q^2 = 0$, 则 $SSim(S_1, S_2)$ 为空值.

传统的评分相似度将用户在不同时间的评分给予了相同的权重, 没有考虑用户的兴趣会随着时间的变化而变化这一实际情况. 用户的消费是一个动态决策的过程, 其消费行为与购买决策、兴趣爱好具有时间关联性. 用户以往的消费行为不仅会影响当下的购买决策, 也能反映当下的兴趣特点, 且时间越近的消费行为对其当下的兴趣反应程度越高^[31]. 德国心理学家艾宾浩斯最初根据人类大脑记忆量与时间的关系提出非线性遗忘曲线, 用来表示人类对新事物的遗忘规律^[32]. 他认为遗忘过程是一种自然的心理现象, 人类对事物的记忆量会随着时间推移而逐渐降低, 且遗忘速度呈现先快后慢的特点. 同理, 用户对消费行为、消费商品的记忆量也存在遗忘现象. 而用户的消费行为是内在心理、兴趣爱好的外化表现, 因此用户的兴趣也符合遗忘规律, 也会随时间的变化而变化. 且随着时间的推移, 用户对某一商品的兴趣程度会逐渐降低, 最终趋向稳定^[33]. 可见, 将用户在不同时间的评分行为赋予不同的权重来反映兴趣的变化, 能够使推荐结果更加精准. 设用户实际评分时间与参照时间的间隔为 t , 则最早评分时间与参照时间的间隔公式为 $t_{min} = \min(t_a - t_r)$, 最晚评分时间与参照时间的间隔公式为 $t_{max} = \max(t_a - t_r)$, 其中 t_a 表示实际评分时间, t_r 表示参照时间. 考虑到用户对方案的偏好随时间呈先快后慢的减弱变化, 在进行评分相似度计算时引入非线性

遗忘函数^[34], 非线性遗忘函数计算公式如下

$$h(t) = \alpha \times \left[\frac{t - t_{min}}{t_{max} - t_{min}} \right]^2 + (1 - \alpha),$$

$$(t_{min} \leq t \leq t_{max}, 0 \leq \alpha \leq 1, 0 < h(t) < 1) \quad (11)$$

其中 α 表示遗忘系数, 反映用户对方案的遗忘速率, 遗忘系数与用户间的兴趣变化呈正比关系. 当 $\alpha = 1$ 时, 用户的偏好发生了改变; 当 $0 < \alpha < 1$ 时, 用户产生了部分非线性遗忘; 当 $\alpha = 0$ 时, 用户的偏好未发生改变. 在推荐系统中, α 受用户偏好的变化程度影响, 若用户兴趣变化快, 则 α 的值较大, 反之则较小. 则考虑时间遗忘权重的用户间评分相似度计算公式如下

$$T_S.Sim(U_1, U_2) =$$

$$\frac{\sum_{i=1}^{p^2} (w_{1i} \times h(t) \times \bar{w}_1) \times (w_{2i} \times h(t) \times \bar{w}_2)}{\sqrt{\sum_{i=1}^{p^2} (w_{1i} \times h(t) \times \bar{w}_1)^2} \times \sqrt{\sum_{i=1}^{p^2} (w_{2i} \times h(t) \times \bar{w}_2)^2}} \quad (12)$$

同理, 考虑时间遗忘权重的方案间评分相似度计算公式如下

$$T_S.Sim(S_1, S_2) =$$

$$\frac{\sum_{j=1}^{q^2} (w_{j1} \times h(t) \times \bar{w}_{s_1}) \times (w_{j2} \times h(t) \times \bar{w}_{s_2})}{\sqrt{\sum_{j=1}^{q^2} (w_{j1} \times h(t) \times \bar{w}_{s_1})^2} \times \sqrt{\sum_{j=1}^{q^2} (w_{j2} \times h(t) \times \bar{w}_{s_2})^2}} \quad (13)$$

2.3 组合相似度计算

将用户间的偏好相似度与评分相似度结合, 形成组合相似度, 从而找到目标用户具有最高相似度的近邻. 用户 U_1 与 U_2 的组合相似度计算公式为

$$Com_Sim(U_1, U_2) = \beta \times T_P.Sim(U_1, U_2) + (1 - \beta) \times T_S.Sim(U_1, U_2) \quad (14)$$

其中 β 表示权重因子, $0 \leq \beta \leq 1$. 对于用户 U_1 , 通过计算其与其他用户间的相似度并过滤掉小于等于预设阈值的用户, 可得到基于该用户的近邻.

同理, PSS 方案 S_1 与 S_2 的组合相似度为

$$Com_Sim(S_1, S_2) = \gamma \times T_P.Sim(S_1, S_2) + (1 - \gamma) \times T_S.Sim(S_1, S_2) \quad (15)$$

其中 γ 表示权重因子, $0 \leq \gamma \leq 1$. 对于方案 S_1 , 通过计算其与其他方案间的相似度并过滤掉小于等于预设阈值的方案, 可得到基于该方案的近邻.

由于本研究分别将用户间偏好相似度与评分相似度、方案间偏好相似度与评分相似度进行了结合, 所以即使在缺少某个相似度的情况下, 仍可

得到用户间组合相似度或方案间组合相似度.

2.4 评分预测

基于用户的过滤方法是通过计算用户间的相似度,找到用户的最近邻后,利用如下公式进行评分预测

$$R(U)_{ij} = \bar{w}_i + \frac{\sum_{k=1}^K Com_Sim(U_i, U_k) \times (w_{kj} - \bar{w}_k)}{\sum_{k=1}^K Com_Sim(U_i, U_k)} \quad (16)$$

基于方案的过滤方法是通过计算方案间的相似度,找到方案的最近邻后,利用如下公式进行评分预测

$$R(S)_{ij} = \bar{w}_{S_j} + \frac{\sum_{l=1}^L Com_Sim(S_j, S_l) \times (w_{il} - \bar{w}_{S_l})}{\sum_{l=1}^L Com_Sim(S_j, S_l)} \quad (17)$$

在对评分进行预测时,当没有对目标方案进行评分的类似用户时,则采用基于方案的过滤方法.当没有由目标用户评分的类似方案时,则采用基于用户的过滤方法.若二者均可使用,则采用组合过滤的方法,公式如下

$$R(Com)_{ij} = \frac{R(U)_{ij} \times \sum_{k=1}^K Com_Sim(U_i, U_k)}{\sum_{k=1}^K Com_Sim(U_i, U_k) + \sum_{l=1}^L Com_Sim(S_j, S_l)} + \frac{R(S)_{ij} \times \sum_{l=1}^L Com_Sim(S_j, S_l)}{\sum_{k=1}^K Com_Sim(U_i, U_k) + \sum_{l=1}^L Com_Sim(S_j, S_l)} \quad (18)$$

在对 PSS 方案的评分预测完毕后,按照预测评分的大小取 top-N 个 PSS 方案提供给目标用户,完成整个配置过程.

3 案例分析

3.1 个性化产品服务方案配置过程

本案例的分析数据来自某传感器制造公司,该企业专业生产岩土工程测量钢弦式系列传感器,同时为客户提供传感器咨询、组装、售后等相应服务.通过整理该公司提供的用户购买记录,选取 10 个具有代表性的方案进行分析,这 10 个方案分别是应力测量系列(S_1)、应变测量系列(S_2)、温度测量系列(S_3)、频率测量系列(S_4)、锚固检测系列(S_5)、位移测量系列(S_6)、张力检测系列(S_7)、压力测量系列(S_8)、反力测量系列(S_9)和集中荷载力测量系列(S_{10}).根据企业的销售记录,选取其中 10 名用户的历史数据进行个性化产品服务方案配置过程分析,其中历史数据包含 10 名用户对方案的使用次数、评分以及评分时间.以用户 U_1 为例,该用户曾使用过方案 S_1 、 S_4 、 S_6 ,现从方案 S_2 、 S_3 、 S_5 、 S_7 、 S_8 、 S_9 、 S_{10} 中为用户 U_1 选择最合适的方案,过程如下.

1) 根据用户 - 方案的偏好矩阵,利用式(1)、式(2)计算用户间和方案间传统偏好相似度,然后利用式(4)、式(5)、式(6)计算用户间和方案间的信任度,取直接信任度系数 $\phi = 0.8$,再利用式(7)、式(8)得到基于信任度的偏好相似度矩阵,如表 4、表 5 所示.

表 4 融合信任度的用户间偏好相似度

Table 4 User preference similarity based on trust

用户	U_1	U_2	U_3	U_4	U_5	U_6	U_7	U_8	U_9	U_{10}
U_1	1.000	0.119	0.188	0.287	0.414	0.315	-0.098	0.281	-0.224	0.370
U_2	0.119	1.000	0.107	0.604	0.036	0.248	0.664	0.293	-0.053	-0.115
U_3	0.188	0.107	1.000	0.304	0.418	0.524	0.223	0.525	-0.224	0.578
U_4	0.287	0.604	0.304	1.000	-0.083	0.710	0.454	0.578	-0.288	0.319
U_5	0.414	0.036	0.418	-0.083	1.000	-0.082	-0.264	-0.110	0.005	0.197
U_6	0.315	0.248	0.524	0.710	-0.082	1.000	0.287	0.624	-0.373	0.471
U_7	-0.098	0.664	0.223	0.454	-0.264	0.287	1.000	0.279	0.116	-0.278
U_8	0.281	0.293	0.525	0.578	-0.110	0.624	0.279	1.000	-0.053	0.424
U_9	-0.224	-0.053	-0.224	-0.288	0.005	-0.373	0.116	-0.053	1.000	-0.340
U_{10}	0.370	-0.115	0.578	0.319	0.197	0.471	-0.278	0.424	-0.340	1.000

表5 融合信任度的方案间偏好相似度

Table 5 Scheme preference similarity based on trust

方案	S_1	S_2	S_3	S_4	S_5	S_6	S_7	S_8	S_9	S_{10}
S_1	1.000	0.461	0.395	-0.164	0.128	-0.039	0.500	0.262	0.279	0.254
S_2	0.461	1.000	0.433	0.328	0.441	-0.221	0.556	0.204	0.615	0.578
S_3	0.395	0.433	1.000	-0.044	0.193	-0.084	0.690	0.642	0.281	0.531
S_4	-0.164	0.328	-0.044	1.000	0.327	-0.491	0.222	0.049	0.098	0.397
S_5	0.128	0.441	0.193	0.327	1.000	-0.334	0.124	0.191	0.488	0.143
S_6	-0.039	-0.221	-0.084	-0.491	-0.334	1.000	-0.297	0.208	-0.013	-0.108
S_7	0.500	0.556	0.690	0.222	0.124	-0.297	1.000	0.501	0.217	0.736
S_8	0.262	0.204	0.642	0.049	0.191	0.208	0.501	1.000	0.202	0.454
S_9	0.279	0.615	0.281	0.098	0.488	-0.013	0.217	0.202	1.000	0.387
S_{10}	0.254	0.578	0.531	0.397	0.143	-0.108	0.736	0.454	0.387	1.000

2) 根据用户评分矩阵, 同时取时间遗忘系数 $\alpha = 0.5$, 利用式(11)、式(12)、式(13), 可得基于时间遗忘权重的评分相似度矩阵, 如表 6、表 7 所示.

表6 融合时间遗忘权重的用户间评分相似度

Table 6 User rating similarity based on time weight

用户	U_1	U_2	U_3	U_4	U_5	U_6	U_7	U_8	U_9	U_{10}
U_1	1.000	-0.599	-0.056	0.068	0.363	-0.243	0.103	0.290	-0.696	0.311
U_2	-0.599	1.000	0.662	0.839	0.394	0.602	0.760	0.593	0.574	0.794
U_3	-0.056	0.662	1.000	0.786	0.474	0.706	0.827	0.807	0.899	0.454
U_4	0.068	0.839	0.786	1.000	0.377	0.745	0.908	0.828	0.670	0.800
U_5	0.363	0.394	0.474	0.377	1.000	0.101	0.292	0.346	0.374	0.446
U_6	-0.243	0.602	0.706	0.745	0.101	1.000	0.842	0.916	0.564	0.290
U_7	0.103	0.760	0.827	0.908	0.292	0.842	1.000	0.867	0.690	0.463
U_8	0.290	0.593	0.807	0.828	0.346	0.916	0.867	1.000	0.537	0.876
U_9	-0.696	0.574	0.899	0.670	0.374	0.564	0.690	0.537	1.000	0.391
U_{10}	0.311	0.794	0.454	0.800	0.446	0.290	0.463	0.876	0.391	1.000

表7 融合时间遗忘权重的方案间评分相似度

Table 7 Scheme rating similarity based on time weight

方案	S_1	S_2	S_3	S_4	S_5	S_6	S_7	S_8	S_9	S_{10}
S_1	1.000	0.092	0.384	0.582	-0.014	0.726	0.342	0.221	0.091	-0.008
S_2	0.092	1.000	0.899	0.554	0.608	-0.249	0.713	0.568	0.816	0.638
S_3	0.384	0.899	1.000	0.762	0.641	0.184	0.886	0.680	0.757	0.683
S_4	0.582	0.554	0.762	1.000	0.166	0.814	0.751	0.676	0.683	0.360
S_5	-0.014	0.608	0.641	0.166	1.000	-0.274	0.621	0.307	0.404	0.440
S_6	0.726	-0.249	0.184	0.814	-0.274	1.000	0.213	0.688	0.276	0.226
S_7	0.342	0.713	0.886	0.751	0.621	0.213	1.000	0.523	0.693	0.686
S_8	0.221	0.568	0.680	0.676	0.307	0.688	0.523	1.000	0.784	0.706
S_9	0.091	0.816	0.757	0.683	0.404	0.276	0.693	0.784	1.000	0.455
S_{10}	-0.008	0.638	0.683	0.360	0.440	0.226	0.686	0.706	0.455	1.000

3) 将用户间及方案间的偏好相似度和评分相似度进行结合, 利用式(14)、式(15)可得用户间和方案间的组合相似度。在本案例中取用户与方案的最近邻数为 3, 再利用式(18)预测 U_1 对未

使用过的方案 S_2 、 S_3 、 S_5 、 S_7 、 S_8 、 S_9 、 S_{10} 的评分, 如表 8 所示。预测评分最高的前三个方案分别是 S_3 、 S_7 和 S_5 , 因此为目标用户 U_1 提供方案 S_3 、 S_7 和 S_5 。

表 8 评分预测矩阵

Table 8 Rating prediction matrix

用户	方案 S_2	方案 S_3	方案 S_5	方案 S_7	方案 S_8	方案 S_9	方案 S_{10}
U_1	2.646	4.136	3.045	3.674	2.390	2.145	2.921

3.2 稀疏性检验

为了验证引入信任关系后对数据稀疏性是否起到缓解作用, 根据企业的销售记录, 选取 300 个用户对 21 个方案的相关数据, 随机分为三组, 获取 3 个稀疏性不同的集合, 分别计算引入信任关系前、后用

户间与方案间相似关系的稀疏度, 结果如表 9 所示。根据实验结果可以看出, 引入信任关系后用户间相似矩阵、方案间相似矩阵的稀疏度都有所降低, 说明信任关系能够扩大目标项的邻居集, 填补部分空缺的相似数据, 从而缓解数据稀疏问题。

表 9 引入信任关系前、后的数据稀疏度

Table 9 Data sparsity before and after introducing trust relationship

稀疏度	数据集 1	数据集 2	数据集 3
原始数据稀疏度	92.19%	93.05%	93.68%
引入信任关系前用户间相似关系稀疏度	89.14%	91.38%	92.51%
引入信任关系后用户间相似关系稀疏度	78.29%	81.23%	79.87%
引入信任关系前项目间相似关系稀疏度	91.9%	90.76%	90.83%
引入信任关系后项目间相似关系稀疏度	85.05%	80.9%	75.05%

3.3 评价标准

为验证该配置方法的有效性, 本研究采用平均绝对误差作为评价标准, 并将该方法与其他协同过滤方法进行对比。平均绝对误差(MAE)表示真实值与预测值之间绝对误差的平均值, 平均绝对误差值越小, 预测的准确性越高。设用户实际评分集为 $R' = \{R'_1, R'_2, \dots, R'_n\}$, 预测评分集为 $R = \{R_1, R_2, \dots, R_n\}$, MAE 的计算公式为

$$MAE = \frac{\sum_{i=1}^n |R_i - R'_i|}{n} \quad (19)$$

3.4 实验结果与分析

根据历史销售记录, 抽取 450 个用户数据, 并将数据按照 7:3 的比例分为训练集和测试集, 对方法进行比较。本研究在考虑信任度与时间遗忘权重时, ϕ 表示直接信任度的重要程度, α 表示用户兴趣变化的快慢, 二者的取值均会影响评分预测的效果。将式(6)中的直接信任度系数 ϕ 分别取 0.2、0.4、0.6、0.8, 将式(11)中的遗忘函数

系数 α 分别取 0.2、0.4、0.6、0.8, 并随机选取 8 名用户(用户 ID = 47、93、129、187、212、283、354、416)计算其 MAE 值, 以此来确定最优的信任度系数和遗忘系数。同时, 将用户最近邻数 K 取 10, 将方案最近邻数 L 取 5, 实验结果如图 4 所示, 其中横坐标为遗忘系数 α 。

从结果可以看出, 在相同的遗忘系数下, 随着信任度系数 ϕ 从 0.2 增加至 0.8, 各用户的 MAE 值均在下降, 预测效果显著增加。这说明对于目标用户而言, 具有共同使用偏好的其他用户对目标用户的影响更大, 即直接信任度比间接信任度对用户影响更大。对于遗忘系数而言, 在相同的信任度系数下, 随着遗忘系数 α 从 0.2 增加至 0.8, 本研究所提出的方法对各用户的预测误差曲线普遍呈现升高的趋势。当遗忘系数 $\alpha = 0.2$ 时, 多数用户的 MAE 值最小, 预测效果最佳, 这说明多数用户的兴趣变化较慢。但仍有个别用户存在不同变化(如用户 ID = 354), 由于其兴趣变化较快, 当 α 增大时, 推荐效果反而增加。

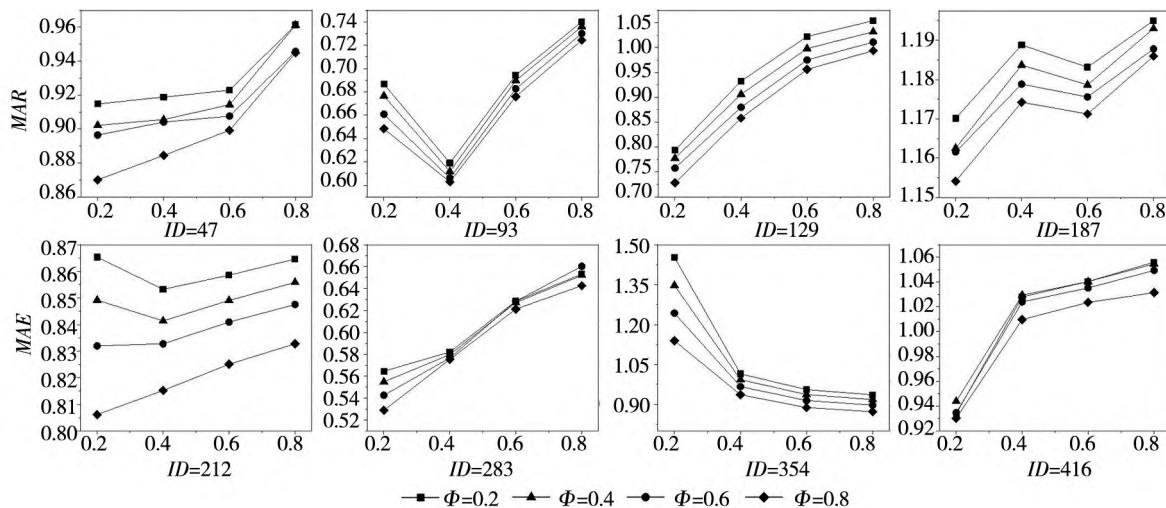


图4 不同用户在不同系数下的评分预测精度

Fig. 4 Rating prediction accuracy of different users under different coefficients

鉴于上述结果,将信任度系数 ϕ 设定为0.8,将遗忘系数 α 设定为0.2,并将本研究方法与以下几种方法进行比较,观察各算法平均绝对误差随用户近邻数量的变化,结果如图5所示.

- 1) 基于偏好的协同过滤方法(P-CF)
- 2) 基于偏好和信任度的协同过滤方法^[35](P-Trust-CF)
- 3) 基于偏好与评分的协同过滤方法^[18](P-S-CF)
- 4) 基于评分的协同过滤方法(S-CF)
- 5) 基于评分与遗忘函数的方法^[36](S-Time-CF)
- 6) 基于偏好、信任度和评分的方法^[29](P-Trust-S-CF)
- 7) 基于偏好、评分和遗忘函数的方法^[32](P-S-Time-CF)
- 8) 本研究所提出的个性化产品服务配置方法,即同时引入信任度与时间遗忘权重的配置方法(P-Trust-S-Time)

从图5可以看出,本研究所提出的方法与其他方法相比,在不同数量的邻居集下普遍有较小的MAE值,具有良好的评分预测效果.可见,在计算相似度时,同时考虑信任度与时间遗忘权重可以更准确地把握用户兴趣的变化,并能够显著提高预测的准确性.

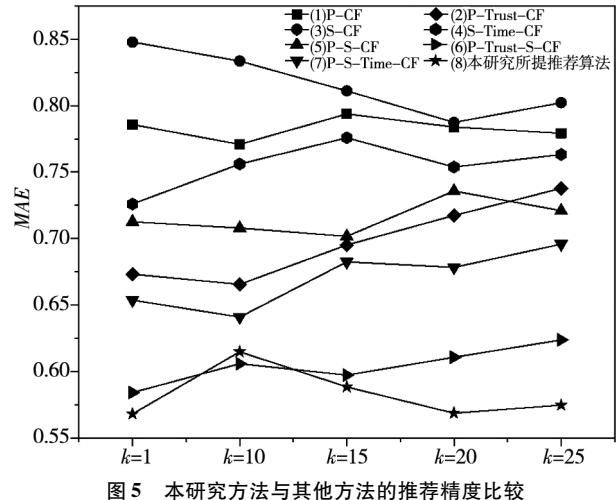


图5 本研究方法与其他方法的推荐精度比较

Fig. 5 Recommendation accuracy comparison between proposed method and other methods

4 结束语

本研究提出了基于信任度与遗忘函数的个性化产品服务配置方法,分别在偏好相似度计算和评分相似度计算中引入用户信任度和时间权重,更加全面地考虑了系统的内在关系,使对用户个性化需求的捕捉更加准确.同时,本研究既考虑了用户间的组合相似度,又考虑了方案间的组合相似度,所以即使缺少某个相似度仍可进行评分预测,极大地缓解了数据稀疏性和冷启动问题.由于以往学者对个性化产品服务方案配置的研究较少,因此本研究对进一步探索产品服务方案配置

模型的构建具有一定的参考价值。此外,由于消费者需求不断向个性化方向转变、制造业不断进行服务化转型升级,企业迫切需要解决如何快速向用户提供个性化方案的问题,因此本研究对于推动制造企业挖掘客户兴趣、获取客户个性化需求、提高自身竞争优势等方面具有一定的参考意义。

通过实验结果可以看出,本研究的方法较其他方法具有更高的预测准确性。但本研究仅考虑

了用户的偏好数据与评分数据,并未考虑用户的评论数据、行为信息等可反映用户兴趣变化的其它数据。在未来的研究中,将考虑更全面的用户信息,建立更能准确反映用户兴趣的模型。同时,本研究对于产品服务方案的特性考虑较少,未来将结合产品服务方案的属性对评分预测的影响,构建更加全面的系统模型,进一步提高方案配置精度。

参 考 文 献:

- [1] Luo J Q, Yang Z C, Zhang Q H, et al. Service outsourcing strategy decision for value creation in manufacturing firms[J]. Journal of Management Science and Engineering, 2021, 7(2): 365 – 386.
- [2] 张在房, 樊蓓蓓. 产品服务系统共生设计理论与方法[J]. 计算机集成制造系统, 2021, 27(2): 328 – 336.
Zhang Zaifang, Fan Beibei. Theory and method for product service system symbiosis design[J]. Computer Integrated Manufacturing Systems, 2021, 27(2): 328 – 336. (in Chinese)
- [3] 窦润亮, 郭均鹏, 田祥龙, 等. 面向客户个性化需求的交互式遗传算法[J]. 管理科学学报, 2016, 19(1): 24 – 34.
Dou Runliang, Guo Junpeng, Tian Xianglong, et al. Interactive genetic algorithm based on customer demand[J]. Journal of Management Sciences in China, 2016, 19(1): 24 – 34. (in Chinese)
- [4] 李 浩, 焦起超, 文笑雨, 等. 面向客户需求的企业产品服务系统实施方案规划方法学[J]. 计算机集成制造系统, 2017, 23(8): 1750 – 1764.
Li Hao, Jiao Qichao, Wen Xiaoyu, et al. Implementation solution planning methodology of enterprise product-service system oriented to customer demand[J]. Computer Integrated Manufacturing Systems, 2017, 23(8): 1750 – 1764. (in Chinese)
- [5] Berry C, Wang H, Hu S J. Product architecting for personalization[J]. Journal of Manufacturing Systems, 2013, 32(3): 404 – 411.
- [6] Esheiba L, Helal I M A, Elgammal A, et al. A data warehouse-based system for service customization recommendations in product-service systems[J]. Sensors, 2022, 22(6): 2118.
- [7] Chen Z, Ming X, Wang R, et al. Selection of design alternatives for smart product service system: A rough-fuzzy data envelopment analysis approach[J]. Journal of Cleaner Production, 2020, (273): 122931.
- [8] Fadeyi J A, Monplaisir L. Instilling lifecycle costs into modular product development for improved remanufacturing-product service system enterprise[J]. International Journal of Production Economics, 2022, (246): 108404.
- [9] 陈耶拉, 耿秀丽. 基于改进协同过滤的个性化产品服务系统方案推荐[J]. 计算机集成制造系统, 2021, 27(1): 240 – 248.
Chen Yela, Geng Xiuli. Recommendation of personalized product-service system scheme based on improved collaborative filtering[J]. Computer Integrated Manufacturing Systems, 2021, 27(1): 240 – 248. (in Chinese)
- [10] 杨 珍, 耿秀丽. 面向个性化产品服务方案的推荐方法与应用[J]. 中国机械工程, 2018, 29(16): 1965 – 1974, 1983.
Yang Zhen, Geng Xiuli. Recommendation method and applications for personalized product service plans[J]. China Mechanical Engineering, 2018, 29(16): 1965 – 1974, 1983. (in Chinese)
- [11] Song W, Sakao T. An environmentally conscious PSS recommendation method based on users' vague ratings: A rough multi-criteria approach[J]. Journal of Cleaner Production, 2017, 172(2): 1592 – 1606.
- [12] Sw A, Mg B, Yue W C, et al. Multi-objective optimization for location-based and preferences-aware recommendation[J]. Information Sciences, 2020, (513): 614 – 626.
- [13] Jeong D, Oh S, Park E. DemoHash: Hashtag recommendation based on user demographic information[J]. Expert Systems

- with Applications, 2022, (210) : 118375.
- [14] Dou R L, Li W, Nan G F, et al. How can manufacturers make decisions on product appearance design? A research on optimal design based on customers' emotional satisfaction [J]. Journal of Management Science and Engineering, 2021, 6 (2) : 177 – 196.
- [15] Qiao Y, Luo X, Li C, et al. Heterogeneous graph-based joint representation learning for users and POIs in location-based social network [J]. Information Processing & Management, 2020, 57(2) : 102151.
- [16] Seng D, Chen G, Zhang Q. Item-based collaborative memory networks for recommendation [J]. IEEE Access, 2020, (8) : 213027 – 213037.
- [17] Wang Y, Deng J, Gao J, et al. Ahybrid user similarity model for collaborative filtering [J]. Information Sciences, 2017. (418) : 102 – 118.
- [18] Zhang W Y, Zhang S, Chen Y G, et al. Combining social network and collaborative filtering for personalised manufacturing service recommendation [J]. International Journal of Production Research, 2013, 51(22) : 6702 – 6719.
- [19] 杜慧滨, 邹宏阳, 张永杰, 等. 异质行为下新能源汽车的技术采纳与扩散 [J]. 管理科学学报, 2021, 24(12) : 62 – 76.
Du Huibin, Zou Hongyang, Zhang Yongjie, et al. Technology adoption and diffusion of new energy vehicle (NEV) under heterogeneous behaviors [J]. Journal of Management Sciences in China, 2021, 24(12) : 62 – 76. (in Chinese)
- [20] Nozari R B, Koohi H. Novel implicit-trust-network-based recommendation methodology [J]. Expert Systems with Applications, 2021, (186) : 115709. 1 – 115709. 22.
- [21] Moody G D, Lowry P B, Galletta D F. It's complicated: Explaining the relationship between trust, distrust, and ambivalence in online transaction relationships using polynomial regression analysis and response surface analysis [J]. European Journal of Information Systems, 2017, 26(4) : 379 – 413.
- [22] Ahmadian M, Ahmadi M, Ahmadian S. A reliable deep representation learning to improve trust-aware recommendation systems [J]. Expert Systems with Application, 2022, 197(7) : 116697. 1 – 116697. 17.
- [23] Lai C H, Lee S J, Huang H L. A social recommendation method based on the integration of social relationship and product popularity [J]. International Journal of Human-Computer Studies, 2019, (121) : 42 – 57.
- [24] Guo G, Zhang J, Zhu F, et al. Factored similarity models with social trust for top-N item recommendation [J]. Knowledge Based Systems, 2017, 122(4) : 17 – 25.
- [25] 罗园, 陈希, 周荣. 基于用户兴趣变化和社会化标注信息的协同过滤推荐方法 [J]. 系统工程, 2020, 38(4) : 151 – 158.
Luo Yuan, Chen Xi, Zhou Rong. Collaborative filtering recommendation method based on user interest change and social tagging information [J]. Systems Engineering, 2020, 38(4) : 151 – 158. (in Chinese)
- [26] Chen J, Lu Y, Shang F, et al. A novel recommendation scheme with multifactorial weighted matrix decomposition strategies via forgetting rule [J]. Engineering Applications of Artificial Intelligence, 2021, 101(10) : 104191.
- [27] Patra B K, Launonen R, Ollikainen V, et al. A new similarity measure using Bhattacharyya coefficient for collaborative filtering in sparse data [J]. Knowledge-Based Systems, 2015, 82(C) : 163 – 177.
- [28] Gohari F S, Aliee F S, Haghghi H. A significance-based trust-aware recommendation approach [J]. Information Systems, 2020, 87(7) : 101421. 1 – 101421. 16.
- [29] Shambour Q, Lu J. A trust-semantic fusion-based recommendation approach for e-business applications [J]. Decision Support Systems, 2012, 54(1) : 768 – 780.
- [30] Parvin H, Moradi P, Esmaeili S, et al. A scalable and robust trust-based nonnegative matrix factorization recommender using the alternating direction method [J]. Knowledge-Based Systems, 2019, (166) : 92 – 107.
- [31] Chen J, Wei L, Liji U, et al. Dynamic evolutionary clustering approach based on time weight and latent attributes for collaborative filtering recommendation [J]. Chaos Solitons & Fractals, 2018, (114) : 8 – 18.

- [32] 朱国玮, 周利. 基于遗忘函数和领域最近邻的混合推荐研究[J]. 管理科学学报, 2012, 15(5) : 55–64.
 Zhu Guowei, Zhou Li. Hybrid recommendation based on forgetting curve and domain nearest neighbor[J]. Journal of Management Sciences in China, 2012, 15(5) : 55–64. (in Chinese)
- [33] 陈 J, 鲁 Y, 尚 F, et al. A fuzzy matrix factor recommendation method with forgetting function and user features[J]. Applied Soft Computing, 2021, 100(1) : 106910.
- [34] 李 T, 金 L, 吴 Z, et al. Combined recommendation algorithm based on improved similarity and forgetting curve[J]. Information, 2019, 10(4) : 130.
- [35] 郑洁, 钱育蓉, 杨兴耀, 等. 基于信任和项目偏好的协调过滤算法[J]. 计算机应用, 2016, 36(10) : 2784–2788, 2798.
 Zheng Jie, Qian Yurong, Yang Xingyao, et al. Collaborative filtering algorithm based on trust and item preference[J]. Journal of Computer Applications, 2016, 36(10) : 2784–2788, 2798. (in Chinese)
- [36] 郑先荣, 曹先彬. 线性逐步遗忘协同过滤算法的研究[J]. 计算机工程, 2007, (6) : 72–73, 82.
 Zheng Xianrong, Cao Xianbin. Research on lineal gradual forgetting collaborative filtering algorithm[J]. Computer Engineering, 2007, (6) : 72–73, 82. (in Chinese)

Personalized product-service configuration based on trust degree and forgetting curve

DOU Run-liang¹, MENG Fan-song¹, NAN Guo-fang¹, ZHOU Xiao-dong¹, LIN Guo-yi^{2, 3}

1. College of Management and Economy, Tianjin University, Tianjin 300072, China;
2. School of Electronic and Information Engineering, Tongji University, Shanghai 201804, China;
3. Shanghai Institute of Intelligent Science and Technology, Tongji University, Shanghai 201804, China

Abstract: With the trend toward personalization and diversity in customer demand, enterprises are faced with the challenge of how to respond to customer demand quickly and provide personalized product service solutions. To locate personalized product service solutions accurately, a personalized product-service configuration method based on trust degree and forgetting curve is proposed. First, the method introduces the trust degree and time weight into the calculation of preference similarity and score similarity. Then, it integrates user similarity and scheme similarity to reduce the impacts of data sparsity and cold starts on rating prediction. Finally, by comparing it with existing methods, the proposed method can improve the accuracy of product service scheme configuration.

Key words: product service solution; trust degree; forgetting curve; collaborative filtering