

基于张量分解技术的个性化云服务推荐算法设计

王 戈¹
WANG Ge

摘 要

传统的推荐算法通常利用矩阵分解来处理二维数据,但在云服务推荐领域,涉及用户、服务和时间等多个维度,形成了复杂的高维数据。矩阵分解在处理这种多维度数据时难以充分捕捉各维度间的复杂交互关系,因此容易出现 QoS 关键数据的丢失和推荐不准确等问题。为了解决这些问题,设计了基于张量分解技术的个性化云服务推荐算法。利用张量分解技术处理云服务高维数据,从用户、服务和时间等三个维度的高维和低维数据,提高推荐元素与用户需求的匹配度,避免了 QoS 数据的丢失。基于 QoS 感知技术构建云服务个性化推荐模型,将经过处理后的数据代入模型中,在模型中整合 QoS 信息和服务功能信息,以有效提升推荐的有效性和准确性。同时,引入文本的语义特征,进一步优化推荐模型,使其能够根据用户输入的语义信息,快速查询并推荐符合需求的服务类别。通过映射云服务空间分布向量推荐查询函数,在推荐模型中激活每一维度的推荐记录,进一步提升推荐结果的准确性。经过对实验结果进行对比验证,证明了所提出的算法在推荐准确性方面具有显著的优越性,并具备在实际生活中广泛应用的潜力。

关键词

QoS 感知; 个性化; 云服务; 推荐算法; 空间分布向量

doi: 10.3969/j.issn.1672-9528.2024.07.021

0 引言

在当今信息化社会,云服务以其灵活、高效的特点,已成为企业和个人获取信息化服务的重要渠道。然而,随着云服务市场的不断发展和服务种类的日益增多,用户在选择云服务时面临着信息过载和选择困难的问题。因此,如何根据用户的个性化需求,为其推荐合适的云服务,成为当前云服务领域亟待解决的问题。个性化云服务推荐算法的设计,旨在通过分析用户的历史行为、服务属性以及时间因素等多维度数据,深入挖掘用户的兴趣偏好和服务需求,从而为用户提供精准、个性化的云服务推荐。这种算法不仅能够帮助用户快速找到符合其需求的服务,提高用户的使用效率和满意度,还能够为云服务提供商提供有价值的市场信息和用户反馈,推动其优化服务质量和提升市场竞争力。因此,研究个性化云服务推荐算法不仅具有重要的理论价值,也具有广阔的应用前景和极大的实践意义。

目前研究人员设计了多种推荐算法。其中,文献[1]中的基于图神经网络的个性化云服务推荐算法,主要是利用图神经网络,在云平台上制造服务资源特征,并通过数据相似度,构建云服务推荐网络图,提高服务推荐的准确性。该算

法在将云平台上的服务资源特征转换为图神经网络可用的节点特征时,难以有效提取出每个特征向量中各维度的重要性和相互关系,导致信息丢失,容易造成对复杂交互关系的捕捉不足。文献[2]中的基于位置与信誉感知深度神经网络的个性化云服务推荐算法,主要是利用地理位置信息,采集云服务历史数据,并通过信誉感知网络,嵌入用户全连接层,输出用户服务特征向量,提高推荐效率。该算法在将信誉感知网络嵌入用户全连接层时,只考虑了用户对服务的打分或简单的好坏评价,而没有考虑到信誉评价的多维度信息,这会限制信誉信息的丰富性,导致难以充分捕捉用户与服务之间复杂的信誉交互关系,推荐结果不够准确。文献[3]中的基于边缘计算的融合多因素的个性化推荐算法充分考虑了用户兴趣、行为等多种因素,利用边缘设备进行数据处理和推荐。该算法在边缘设备上生成推荐结果时,受到设备计算能力和存储容量的限制,可能无法对包含多种因素的大规模数据进行全面分析,从而影响了最终推荐结果的准确性和个性化程度。文献[4]中的基于朴素贝叶斯的推荐算法虽然在简单性和可解释性方面表现较好,但对于复杂的推荐场景和多维度数据处理能力有限,容易受到特征独立性假设的限制,并且在实际应用中可能面临数据稀疏性和冷启动等问题。

针对传统推荐算法存在的问题,本研究提出了基于 QoS

1. 开封文化艺术职业学院计算机学院 河南开封 475000

感知的个性化云服务推荐算法。该算法创新地引入了张量分解技术,用于处理云服务中的高维数据。通过深入分析用户、服务和时间等多个维度,该算法能够更准确地捕捉各维度间的交互关系,提高推荐元素与用户需求的匹配度,有效避免 QoS 数据的丢失。基于 QoS 感知技术构建了云服务个性化推荐模型,在模型中充分整合了经过处理后的数据、QoS 信息和服务功能信息,旨在提升推荐的有效性和准确性。同时,引入了文本的语义特征,进一步优化推荐模型,使其更准确地理解用户的语义信息,从而为用户提供更符合需求的云服务推荐。

1 个性化云服务 QoS 感知推荐算法设计

1.1 张量分解个性化云服务高维数据

传统的推荐算法在处理云服务推荐这类涉及用户、服务和时间等多个维度的高维数据时,存在诸多挑战。矩阵分解作为传统算法的核心技术,在处理二维数据时表现良好,但在面对高维数据时,其局限性便显现出来。这主要是因为矩阵分解难以充分捕捉各维度间的复杂交互关系,导致 QoS 数据丢失和推荐不准确等问题。为了克服这些挑战,本研究通过引入张量分解技术将高维数据分解为低维数据,从而避免数据维度不同对推荐结果的影响。张量分解可以通过分析用户、服务和时间等多个维度之间的关系,找出隐藏在数据中的潜在结构和规律。这有助于更准确地捕捉各维度间的复杂交互关系,从而提高推荐的准确性。同时,张量分解还可以保留 QoS 数据,确保推荐结果能够全面反映服务的性能和质量。

在云服务推荐的数据中,一个张量可以被理解为一个多维数组。而 N 阶张量则代表 N 个向量空间的张量元素。通过进行张量分解,可以处理高维数据并获得低维数据,将其转化成同一维度的数据,从而避免数据维度不同对推荐结果的影响。本文从用户、服务、时间这三个维度出发,利用三阶张量进行分析,以确保推荐元素能够满足实际需求。三阶张量示例如图 1 所示。




图 1 三阶张量示例图

如图 1 所示,一阶张量代表一个向量,二阶张量代表一个矩阵,三阶张量代表多维数据。其中, i 表示用户张量数据;

j 表示服务张量数据; k 表示时间段张量数据。在张量分解高维数据的过程中,二阶张量用 A 矩阵表示,向量用 a 表示,三阶张量元素用 i, j, k 表示^[5]。将 A, a, i, j, k 表示张量分解阵列的指数,子阵列形成。云服务高维数据作为张量矩阵行、列的高阶模拟,固定其他维度指标,仅改变一个维度指标,即可分解高维数据。三阶张量具有三类纤维,通过 2-范数,分解高维数据,其公式为:

$$\|i, j, k\| = \sqrt{\sum_{a=1}^A \dots \sum_{a=1}^A (x_{jk}, x_{ik}, x_{ij})^2} \quad (1)$$

式中: $\|i, j, k\|$ 为三阶张量分解后的高维数据; x_{jk} 为服务张量数据与时间段数据中存在的高维数据; x_{ik} 为用户数据、时间段数据中存在的高维数据; x_{ij} 为用户数据、服务数据中存在的高维数据。将高维数据分解处理完成之后,本文对低维数据进行处理。张量之间相乘的过程较为复杂,增加推荐算法的负担。因此,本文仅考虑 i, j, k 与 A 的情况,将各个张量相乘,找出三阶张量中存在的低维数据^[6]。也就是说,通过 $i \times A, j \times A, k \times A$ 的运算,得到低维数据。再将低维数据代入式(1)中,得到 $\|i', j', k'\|$,从而完成低维数据的处理任务。

张量分解作为一种多维数据处理技术,能够有效地分析用户、服务、时间这些维度之间的关系,找出隐藏在数据中的潜在结构和规律。这为基于 QoS 感知构建个性化推荐模型提供了坚实的数据基础。

1.2 基于 QoS 感知的个性化云服务推荐模型构建

QoS(服务质量)数据是云服务推荐中至关重要的信息,它反映了服务的性能和质量。张量分解在处理高维数据时能够保留 QoS 数据,确保推荐结果能够全面反映服务的实际情况。为此,当基于 QoS 感知构建个性化推荐模型时,可以利用张量分解处理后的数据作为输入。这些数据已经经过维度分析和结构优化,能够更好地反映云服务的特点和用户的需求。详细过程描述如下。

将高维数据、低维数据处理完成之后,云服务数据中各个元素的有效性更高。将 $\|i, j, k\|, \|i', j', k'\|$ 作为输入数据,代入推荐模型中,能够避免 QoS 数据丢失的问题^[7]。处理集成推荐阶段的 QoS 信息、公布/发现/绑定服务的功能信息,为用户提供准确的服务能力。云计算的架构分为 SaaS、PaaS、IaaS 等三个层次,分别完成软件服务、平台服务、基础设施服务等任务。在云平台中,集成 QoS 信息,能够利用云计算的容错副本,提高 QoS 信息的有效性。QoS 数据的属性包括可用性、可访问性、响应时间、吞吐量等方面,通过 QoS 建立的推荐模型,能够强化推荐算法的性能,使服务能够快速、连续地完成推荐功能^[8]。在整个 SOA 中,考虑 QoS 的变化,并根据用户的需求,描述推荐模型的非功能性变化,

从而快速找出符合用户需求的服务。QoS 数据包含功能性与非功能性，所有的数据均存储在质量数据库中，每一个三角形代表一个服务推荐记录。则 QoS 的空间描述如下：

$$Q=(E,D,R) \tag{2}$$

式中：\$Q\$ 为 QoS 的空间描述，表示服务推荐的质量空间；\$E\$、\$D\$、\$R\$ 为云服务空间，分别表示云服务期望值、可度量 QoS 属性值、云服务评价指标。将 \$E\$、\$D\$、\$R\$ 形成一个三角形，表示一条推荐记录。QoS 信息并不能完全反映最新的服务信息，在云服务运行阶段监视、捕获、存储与云服务相关的 QoS 信息，能够生成 QoS 全生命周期信息流，从而确保 QoS 信息的全面性^[9]。在监视结果中，定义一个七元组 \$q=\{id,t,s_p,c_m,E,D,R\}\$，\$id\$ 表示推荐记录号，\$t\$ 表示推荐时间标签；\$s_i\$ 表示服务；\$c_m\$ 表示用户。每个质量空间有三个点，对应三阶张量，各个空间点与张量的连接，表示不同的推荐记录。由此构建出推荐模型，表达式为：

$$r=Q\frac{n\sum D_hD_e-\sum D_h\sum D_e}{\sqrt{[n\sum (D_h)^2-(D_e)^2]}\cdot\frac{\|i,j,k\|+\|i',j',k'\|}{n}} \tag{3}$$

式中：\$r\$ 为推荐模型表达式，表示 \$D\$ 空间内交叉推荐记录的相关性；\$n\$ 为 \$D\$ 空间交叉的点数；\$D_h\$ 为 \$D\$ 空间所在范围中，推荐有效记录的上限；\$D_e\$ 为 \$D\$ 空间所在范围中，推荐有效记录的下限。\$r\$ 的取值范围设定为 \$[-1,1]\$，\$r=-1\$ 时，证明交叉推荐记录存在负相关的关系；\$r=1\$ 时，证明交叉推荐记录存在正相关的关系；\$r=0\$ 时，证明交叉推荐记录不相关。将 \$r=0\$ 的推荐数据剔除，\$r=-1\$ 的推荐记录存储在备选空间中，\$r=1\$ 的推荐记录推荐给用户，确保推荐的准确性。

1.3 云服务空间分布向量映射下的推荐模型维度激活

基于 QoS 感知构建个性化推荐模型后，引入文本的语义特征，旨在进一步优化推荐模型的功能和性能。通过这样的方式，模型能够根据用户输入的语义信息，更快速、更准确地查询并推荐符合其需求的服务类别。在此基础上，通过映射云服务空间分布向量推荐查询函数，模型能够在推荐过程中激活每一维度的推荐记录。这样做有助于更全面地考虑不同维度对推荐结果的影响，提高推荐的准确性和相关性，从而实现个性化推荐^[10]。

在推荐模型中，映射空间分布向量推荐查询函数，从而激活每一维度的推荐记录，进一步提高推荐结果的准确性。云服务卡空间分布向量数据如表 1 所示。如表 1 所示，在用户打开云服务平台时，平台获取用户 ID 的地理位置经纬度。根据地理位置信息分析用户的偏好，再输入语义特征，实现推荐的全面性。语义特征映射到分布向量空间的过程表示为：

$$v=r[\varphi(D_1)\oplus\varphi(D_2)\oplus\varphi(D_3)\cdots\oplus\varphi(D_3)] \tag{4}$$

式中：\$\mathbf{v}\$ 为分布向量矩阵；\$\varphi\$ 为推荐查询函数；\$D_1\$、\$D_2\$、\$D_3\$

为映射到 \$D\$ 空间的语义特征；\$\varphi(D_1)\$、\$\varphi(D_2)\$、\$\varphi(D_3)\$ 为查询函数返回语义特征的词向量；\$\oplus\$ 为连接操作。将映射到 \$\oplus\$ 的 \$\varphi(D_1)\$、\$\varphi(D_2)\$、\$\varphi(D_3)\$ 作为查询字段，输入任意字段，查询得到更加准确的推荐结果，从而避免了推荐失误的问题。

表 1 云服务空间分布向量数据表

云服务 ID	地理位置经度	地理位置纬度	查询响应时间 /ms
CS001	116.407 4	39.904 2	≤100
CS002	121.473 7	31.230 4	≤150
CS003	103.833 3	30.666 7	≤80
CS004	123.400 0	10.120 0	≤200
CS005	-79.935 2	40.730 6	≤12
CS006	104.066 7	30.666 7	≤95
CS007	-43.172 9	-22.906 8	≤180
CS008	2.352 2	48.856 6	≤110

2 实验验证

为了验证本文所设计的算法是否能够满足个性化云服务推荐的需求，进行了以下实验分析。实验结果以对比的形式呈现，其中包括文献 [1] 中基于图神经网络的推荐算法、文献 [2] 中基于位置与信誉感知深度神经网络的推荐算法，以及本文提出的基于张量分解技术的推荐算法。具体的实验准备过程以及实验结果如下。

2.1 实验准备

在本次实验中，以真实用户在云服务平台上的行为数据（包括用户对不同服务的点击、评分、购买等操作记录数据）作为实验数据，以衡量推荐算法的性能。这些真实数据受到调用时间、用户行为以及服务地理位置等多种因素的影响，导致出现 Qos 数据丢失和推荐不准确等问题。为了解决此问题，本研究从用户、服务、时间这三个维度出发，利用三阶张量进行分析，以确保推荐元素能够满足实际需求。处理之后的数据集统计量如表 2 所示。

表 2 数据统计量表

数据类别	响应时间	吞吐量
取值范围	0 ~ 20 s	0 ~ 1000 kbit/s
数据平均值	3.165 s	9.609 kbit/s
用户数目	142	142
服务数目	4532	4532
时间段数目	64	64
总记录数	30 287 611	30 287 611

根据表 2 所示，经过张量分解后，本研究能够有效地保留 QoS 数据，从而确保推荐结果能够充分、真实地反映服务的实际情况。在数据集中，包含了服务响应时间和吞吐量等

两种 QoS 信息,同时用户数目、服务数目、时间段数目以及总记录数保持一致,这充分证明了经过张量处理后的数据集内的 QoS 数据处于可用状态。

为了满足用户云服务需求,本次实验从数据采集、数据选择、数据聚合、服务排序等方面,简化云服务推荐流程,如图 2 所示。




图 2 云服务推荐流程图

如图 2 所示,将表 2 中的数据处理集成推荐阶段的 QoS 信息,以监测数据的形式输入数据采集模块中,用户数据以用户评分的形式输入数据采集模块中。通过数据选择、聚合、服务排序,生成最终的推荐结果,并对推荐结果的性能指标进行分析,判断推荐的准确性。

2.2 实验指标

在上述实验条件下,本文选取 4 种推荐性能的度量指标,分析推荐服务的有效性。度量指标分别为 MAE 值、NMAE 值、RMAE 值、MRE 值以及召回率。其中,MAE 值计算公式为:

$$MAE = \frac{\sum_{u,i} |P_{ui} - r_{ui}|}{N} \quad (5)$$

式中:MAE 为云服务推荐的平均绝对误差; P_{ui} 为用户 u 对推荐服务 i 的预测评分; r_{ui} 为用户 u 对推荐服务 i 的实际评分; N 为所有推荐服务预测项目。NMAE 值计算公式为:

$$NMAE = \frac{MAE}{\sum_{u,i} r_{ui} / N} \quad (6)$$

式中:NMAE 为云服务推荐的归一化平均绝对误差。RMAE 值计算公式为:

$$RMAE = \sqrt{\frac{\sum_{u,i} (P_{ui} - r_{ui})^2}{N}} \quad (7)$$

式中:RMAE 为云服务推荐的均方根误差。MRE 值计算公式为:

$$MRE = M \left(\frac{|P_{ui} - r_{ui}|}{r_{ui}} \right) \quad (8)$$

式中:MRE 为云服务推荐的相对误差中值; M 为中值参数。MAE、NMAE、RMAE、MRE 的取值范围均设定为 $0 \sim 1$,上述各值越趋近于 0,推荐结果越能够满足云服务需求;越

趋近于 1,推荐结果无法满足云服务需求。在其他条件均已知的情况下,本文随机选取 4 种云服务推荐场景,并分析各个场景下的 MAE 值、NMAE 值、RMAE 值、MRE 值。

召回率计算公式为:

$$\eta = \lambda / \theta \quad (9)$$

式中: λ 表示被正确预测为正例的样本数; θ 表示所有实际为正例的样本数。

2.3 实验结果分析

为了进一步验证本文算法的可行性,对比了文献 [1] 基于图神经网络推荐算法的性能、文献 [2] 基于位置与信誉感知深度神经网络推荐算法的性能,以及本文设计的基于张量分解技术的推荐算法的性能。对比结果如表 3 所示。

表 3 实验结果

算法	性能指标	云服务推荐场景			
		小型企业云服务推荐场景	大数据分析场景	跨地域业务部署场景	高并发访问场景
文献 [1] 推荐算法	MAE	0.262	0.146	0.082	0.106
	NMAE	0.096	0.027	0.014	0.075
	RMAE	0.128	0.072	0.056	0.093
	MRE	0.356	0.267	0.142	0.158
文献 [2] 推荐算法	MAE	0.074	0.065	0.017	0.032
	NMAE	0.024	0.013	0.004	0.008
	RMAE	0.056	0.026	0.008	0.016
	MRE	0.086	0.072	0.026	0.047
本文设计的推荐算法	MAE	0.004	0.003	0.001	0.002
	NMAE	0.002	0.001	0.000	0.001
	RMAE	0.003	0.002	0.000	0.002
	MRE	0.005	0.004	0.002	0.003

如表 3 所示,上述指标存在一定的顺序关系,MRE 值 $>$ MAE 值 $>$ RMAE 值 $>$ NMAE 值。在其他条件均一致的情况下,使用文献 [1] 基于图神经网络的个性化云服务推荐算法之后,MAE 值在 $0.05 \sim 0.3$ 的范围内变化,NMAE 值在 $0.01 \sim 0.1$ 的范围内变化,RMAE 值在 $0.05 \sim 0.15$ 的范围内变化,MRE 值在 $0.1 \sim 0.4$ 的范围内变化。由此可见,该算法的个性化推荐精准度不佳,增加用户检索服务内容的时间,影响云服务效率。使用文献 [2] 基于位置与信誉感知深度神经网络的个性化云服务推荐算法之后,MAE 值在 $0.01 \sim 0.08$ 的范围内变化,NMAE 值在 $0.004 \sim 0.03$ 的范围内变化,RMAE 值在 $0.005 \sim 0.06$ 的范围内变化,MRE 值在 $0.02 \sim 0.09$ 的范围内变化。由此可见,该算法的推荐性能优于文献 [1] 方法,但其整体指标仍较大,亟须对其进行进一步优化。使用本文设计的基于张量分解技术的个性化云服务推荐算法后,MAE 值、NMAE 值、RMAE 值、MRE 值均保持在 0.006 以内,推荐准确性显著提升。这主要在于本文算法利用张量分解技术处理云服务的高维数据,能够充分保留 QoS 数据,从而确保最终的推荐结果能够全面而真实地反映服务的实际状况。

这样的处理方式不仅提高了推荐的准确性，也增强了推荐结果的可信度。

为了进一步验证本文算法的高效性，以召回率作为实验指标，对比文献[1]基于图神经网络推荐算法的性能、文献[2]基于位置与信誉感知深度神经网络推荐算法的性能，以及本文设计的基于张量分解技术的推荐算法的性能。对比结果如图3所示。




图3 不同算法感知推荐召回率对比

根据图3的数据分析，本文算法相较于传统算法在推荐召回率方面表现更优秀，这表明所提算法能更有效地将相关内容推荐给用户，进而提高用户对推荐内容的涵盖度和满意度。实验结果表明，这一优势可能得益于采用了更为智能、个性化的推荐算法。该算法运用了张量分解技术处理云服务的高维数据。通过充分利用用户、服务和时间这三个维度的高维和低维数据，算法显著提高了推荐元素与用户需求的匹配度，有效避免了QoS数据丢失的问题。此外，基于QoS感知技术构建的个性化推荐模型，整合了处理后的数据、QoS信息和服务功能信息，进一步提升了推荐的有效性和准确性。同时，引入文本的语义特征和映射云服务空间分布向量的推荐查询函数，也有效提高了推荐结果的质量和准确性。这种优势有望全面提升推荐系统的整体性能，增强用户的黏性和满意度，对提升推荐系统的性能和用户体验具有积极的推动作用。

3 结语

云计算作为当今计算领域的热点，为众多企业和个人用户带来了前所未有的便捷。然而，随着云服务市场的迅速扩张，数据量急剧增长，如何高效地从海量数据中筛选出符合用户个性化需求的服务，已成为当前亟待解决的关键问题。本文针对这一问题，提出了一种基于张量分解技术的个性化云服务推荐算法。该算法通过引入张量分解技术，有效处理云服务中涉及的多维度高维数据，从而能够更全面地捕捉用户、服务和时间之间的复杂交互关系，避免了QoS数据的

丢失，显著提升了推荐的准确性。此外，算法还构建了基于QoS感知的云服务个性化推荐模型，通过整合处理后的数据、QoS信息和服务功能信息，进一步提升了推荐的有效性和精准度。同时，结合文本的语义特征和云服务空间分布向量的映射，使得推荐系统能够更智能地理解用户意图，从而提供更为精准的服务推荐。经过实验验证，该算法在推荐准确性方面表现出色，展现出在实际应用中的巨大潜力。它不仅能够提升云服务推荐系统的性能，更能显著增强用户的满意度和黏性，为云服务的普及和发展注入新的活力。

参考文献：

[1] 董学文, 石宇强, 田永政. 基于图神经网络的云制造服务推荐方法研究[J]. 工业工程, 2023, 26(5): 115-123+167.

[2] 朵琳, 张园园, 韦贵香. 基于位置与信誉感知深度神经网络的云服务质量预测[J]. 通信技术, 2022, 55(10): 1314-1322.

[3] 金焕章, 朱容波, 刘浩, 等. 基于边缘计算的融合多因素的个性化推荐算法[J]. 中南民族大学学报(自然科学版), 2024, 43(2): 217-225.

[4] 严海兵, 周刚, 朱振刚, 等. 基于朴素贝叶斯的学术论文推荐算法研究[J]. 苏州科技大学学报(自然科学版), 2023, 40(4): 69-75.

[5] 李嘉雯, 周捷, 吴瑕玉. 我国个性化推荐算法现状可视化分析——对服装领域发展趋势的思考[J]. 国际纺织导报, 2023, 51(6): 42-46.

[6] 李挺, 金福生, 李荣华, 等. Light-HGNN: 用于圈层内容推荐的轻量同质超图神经网络[J]. 计算机研究与发展, 2024, 61(4): 877-888.

[7] 陈文婷, 陈学勤, 王伟津, 等. 面向稀疏数据场景的生成对抗网络推荐算法[J]. 福州大学学报(自然科学版), 2023, 51(4): 467-474.

[8] 许建龙, 林健, 黎宇森, 等. 分布式用户隐私保护可调节的云服务个性化QoS预测模型[J]. 网络与信息安全学报, 2023, 9(2): 70-80.

[9] 王志远, 闭应洲, 武文霖, 等. 基于贝叶斯个性化排名和信息传播的TOP-K推荐算法[J]. 南宁师范大学学报(自然科学版), 2022, 39(4): 44-48.

[10] 潘禹辰, 吴德胜. 关注线上评价还是在意线下距离?——基于推荐效果的O2O商业模式下用户选择决策行为特征分析[J]. 工程管理科技前沿, 2022, 41(1): 90-96.

【作者简介】

王戈(1981—)，女，河南开封人，硕士研究生，副教授，研究方向：计算机网络、云计算。

(收稿日期：2024-04-12)