

考虑需求优先性的在线医患双边匹配方法

范婷睿, 刘盾, 叶晓庆

引用本文

范婷睿, 刘盾, 叶晓庆. 考虑需求优先性的在线医患双边匹配方法[J]. 计算机科学, 2023, 50(10): 28-36.

FAN Tingrui, LIU Dun, YE Xiaoqing. [Two-sided Matching Method for Online Consultation Platform Considering Demand Priority](#) [J]. Computer Science, 2023, 50(10): 28-36.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[介粒度空间中的最优粒度选择和属性约简](#)

Optimal Granularity Selection and Attribute Reduction in Meso-granularity Space
计算机科学, 2023, 50(10): 71-79. <https://doi.org/10.11896/jsjcx.230500218>

[覆盖多粒度下的形式概念更新方法](#)

Method of Updating Formal Concept Under Covering Multi-granularity
计算机科学, 2023, 50(10): 18-27. <https://doi.org/10.11896/jsjcx.230600049>

[不协调广义决策多尺度序信息系统的最优尺度选择与规则提取](#)

Optimal Scale Selection and Rule Acquisition in Inconsistent Generalized Decision Multi-scale Ordered Information Systems
计算机科学, 2023, 50(6): 131-141. <https://doi.org/10.11896/jsjcx.220800149>

[基于表示学习的知识图谱推理研究综述](#)

Survey of Knowledge Graph Reasoning Based on Representation Learning
计算机科学, 2023, 50(3): 94-113. <https://doi.org/10.11896/jsjcx.220900136>

[随机多尺度序决策系统的最优尺度选择](#)

Optimal Scale Selection in Random Multi-scale Ordered Decision Systems
计算机科学, 2022, 49(6): 172-179. <https://doi.org/10.11896/jsjcx.220200067>

考虑需求优先性的在线医患双边匹配方法

范婷睿¹ 刘盾¹ 叶晓庆²

1 西南交通大学经济管理学院 成都 610031

2 西南交通大学计算机与人工智能学院 成都 611756

(fantingrui128@163.com)

摘要 近年来,随着互联网与智慧医疗的飞速发展,在线问诊平台逐渐成为满足大众基本医疗需求的重要渠道。随着在线问诊平台患者和医生数量的不断增长,医生回答参差不齐、患者提问响应不及时、答复率严重不足等问题不断涌现。如何从大量的在线医疗内容中挖掘患者需求信息和医生服务信息,刻画患者需求满意度和医生的服务能力,实现精确匹配是亟需解决的问题。基于此,文中提出了一个融合机器学习算法的多阶段匹配模型,用于提高匹配精度和多样性。首先,从医生和患者两个视角,利用机器学习算法和情感分析工具,深度挖掘患者服务需求和医生服务能力,同时考虑到患者强烈的风险规避态度,引入前景理论描述患者风险偏好。然后,考虑到患者需求的优先性,以粒计算思想为指导,以提高医患匹配的准确性和多样性为目的,构建多阶段动态匹配模型。最后,通过爬取好大夫网站的真实数据来进行实验,结果验证了所提方法的有效性。

关键词: 线问诊平台; 医患双边匹配; 粒计算; 用户生成内容; 多源信息

中图法分类号 TP181

Two-sided Matching Method for Online Consultation Platform Considering Demand Priority

FAN Tingrui¹, LIU Dun¹ and YE Xiaoqing²

1 School of Economics and Management, Southwest Jiaotong University, Chengdu 610031, China

2 School of Computer and Artificial Intelligence, Southwest Jiaotong University, Chengdu 611756, China

Abstract In recent years, with the rapid development of the Internet and smart medical care, online consultation platforms have gradually become an important channel to meet the basic medical needs of the public. With the continuous increase in the number of patients and doctors on the online consultation platform, the quality of doctors' consultation responses is uneven, and problems such as untimely response to patients' questions and a serious shortage of response rates continue to emerge. Therefore, How to mine patients' demand information and doctors' service information from a large amount of online medical content, describe patients' demand satisfaction and doctors' service ability, and achieve accurate matching are problems that need to be solved. Based on this, this paper proposes a multi-stage matching model combined with machine learning algorithms to improve matching accuracy and diversity. First of all, from the perspective of doctors and patients, this paper uses machine learning algorithms and sentiment analysis tools, combined with prospect theory, to fully evaluate patient preferences and doctors' professional capabilities. Secondly, considering the hierarchical structure of patient needs, this paper constructs a multi-stage dynamic matching model guided by the idea of granular computing. Finally, the validity of the method is verified through the research on real database on haodf.com.

Keywords Online consultation platform, Patients-Doctors matching, Granular computing, User-generated content, Multi-source data

1 引言

近年来,随着在线医疗服务平台、互联网医疗的蓬勃

兴起,加之网络资源的便利性和低成本,越来越多的患者已开始使用在线医疗平台来解决健康问题。然而,考虑到在线医疗信息数量庞大、相关网站质量参差不齐,缺乏专业医疗知识

到稿日期:2023-06-05 返修日期:2023-07-28

基金项目:国家自然科学基金(62276217, 61876157);四川省杰出青年科学基金(2022JDJQ0034);中国博士后科学基金面上资助(2022M722629);中央高校基本科研业务费资助(2682022ZTPY057)

This work was supported by the National Natural Science Foundation of China(62276217, 61876157), Science Fund for Distinguished Young Scholars of Sichuan Province(2022JDJQ0034), China Postdoctoral Science Foundation(2022M722629) and Fundamental Research Funds for the Central Universities of Ministry of Education of China(2682022ZTPY057).

通信作者:刘盾(newton83@163.com)

的患者往往难以选择到合适的医生来解决自身的健康问题。在这种情况下,由于患者对医疗信息的了解不充分,其需求和医生的服务常常无法得到合理匹配,这会导致患者满意度降低,最终影响在线问诊平台的运营^[1]。因此,如何充分利用在线医疗信息,挖掘其隐含的患者需求信息和医生服务信息以提高医疗服务匹配的准确性和多样性,是值得研究的问题。

医疗服务的核心在于缓解病痛,而医生的专业能力又与治疗效果直接相关,因此挖掘医生专业能力对于提高医疗服务质量至关重要。现有医生匹配研究中对于医生专业能力的挖掘主要集中在基于问题和基于文本的相似度挖掘上^[2-3]。单从问题或咨询文本的相似度出发,只能从较粗的粒度上反映医生的专业能力,无法准确反映医生在各疾病领域下的专业能力,具有一定的局限性。因此,如何从疾病领域挖掘医生的专业信息以评估医生提供服务的能力,是亟需解决的重要问题。

此外,患者作为医疗服务的主体,其对医生的个性化需求会在很大程度上影响匹配结果^[4]。在实际就诊过程中,患者会从不同的角度对潜在的候选医生进行评估^[5],如医生职称、经验、服务的患者数量以及就诊患者评论等。其中,评论文本又因其包含了大量患者对医生服务质量的评价,在反映患者真实需求方面有着重要意义^[6-9]。然而,现有研究大多只考虑医生星级评分等显性医生特征对患者需求的影响,忽略了评论文本中更细粒度的隐性特征的影响。因此,如何从在线医疗信息中挖掘出患者的需求,构建患者对医生的需求评价体系同样值得探究。

进一步地,在医患匹配问题中,服务需求评价指标的权重和患者风险态度都可能会对最后的结果产生影响。一方面,医疗服务作为服务型产品,具有价值高、体验风险高、专业性强的特点。当疾病无法治愈时,不仅会给患者带来时间和金钱的损失,还会给患者的身体和生活带来负面影响。因此,患者在选择医疗服务时可能会产生强烈的风险规避态度。另一方面,受个人偏好和专业知识等因素的影响,患者在选择医生时考虑的需求优先序不同,对医生的满意程度也不尽相同^[8]。例如,有的患者更看重医生的职称和经验,而有的患者则更看重服务态度和价格。由于医疗资源有限,因此并非每个患者的所有需求偏好都能够被完全满足。在这种情况下,患者的需求可能会产生变化^[10],有的患者会选择降低自身需求来保证尽快被匹配;而有的患者则宁愿等待,直至完全满足自身需求的医生空闲为止。可以看到,忽略患者需求的优先性,会使得部分需求的重要程度被削弱,并导致无法反映患者对医生的真实需求。因此,如何构建一个考虑患者风险偏好和患者需求优先性的匹配模型也是需要解决的问题。

基于上述分析,本文提出了一种融合机器学习方法的多阶段医患匹配模型,用于帮助在线问诊平台整合和利用在线医疗信息,在考虑患者需求优先性和风险偏好的情况下,以提高医患匹配的准确性和多样性为目的,进行多阶段医患匹配决策,最终提升医患匹配质量和效率。

2 相关研究

2.1 在线医疗信息挖掘

在大数据时代,面对大量以不同形式呈现在在线问诊平台的医疗信息,传统的数据样本统计分析已经无法满足在线医疗信息挖掘的需求,国内外众多学者已开始将人工智能技术应用于在线医疗信息挖掘研究中。作为一种重要的主题提取模型,LDA(Latent Dirichlet Allocation)近年来已在大规模文本挖掘和信息处理上表现出诸多优势,并已在在线医疗领域取得成功的应用。Kowalski^[6]使用 LDA 主题模型从评论中提取主题,以了解患者对医护人员的偏好。Li 等^[7]基于在线问答社区中的癌症信息,利用 LDA 获取其主题范围,并据此建立编码规则,实现对用户需求特征的测度。Agarwal 等^[11]使用 LDA 在 Yelp 和 Google 上对特殊药物的在线评论信息进行主题特征提取,来探究影响患者满意度的因素。Ahani 等^[12]使用 LDA 等机器学习方法来提取医疗旅游在线评论,以揭示游客对医疗旅游服务的选择偏好。Alodadi 等^[13]使用 LDA 进行在线医疗评论主题特征提取,以研究在线医疗评论信息对患者选择医生的帮助程度。

与此同时,不少研究者还利用情感分析技术挖掘消费者对产品或服务的满意度,以此来衡量产品或服务价值的价值,帮助患者合理决策。Liu 等^[14]使用 LDA 和情感分析进行主题建模,利用在线医疗评论反映线上私人医疗服务的服务质量与患者满意度。Abirami 等^[9]利用情感词典,从在线医疗评论中提取情绪得分,并将其应用于医院排名的多准则决策中。Ye 等^[15]结合机器学习方法构建模型进行相似度匹配和情感分析,通过层次分析法来衡量信号的相对重要性,最后根据汇总得分得到医生排名以帮助患者选择医生。综上所述,挖掘在线医疗信息的潜在价值是一项非常重要的研究。基于此,本文利用机器学习方法和情感分析工具挖掘在线医疗信息中的患者服务需求和医生专业能力,以帮助在线问诊平台进行医患匹配决策。

2.2 双边匹配研究

医疗服务供需匹配本质上属于双边匹配决策的范畴^[16]。双边匹配决策源于 1962 年 Gale 等^[17]的研究。此后,国内外学者针对不同实际问题,从经济学和管理学等视角出发,运用决策优化和数学规划方法等方法对双边匹配问题进行扩展和探索^[18]。Chen 等^[19]以最大化患者满意度、最大化均衡医疗服务提供者工作数量等为目标构建多目标优化模型,确定医疗服务提供者与患者的双边匹配方案。Yuan 等^[20]基于患者期望水平,针对择期手术患者和医生的匹配问题,提出了一种新的匹配决策方法。Singh 等^[21]考虑了聘请医疗顾问的真实最优机制,保障所提方法能够获得稳定的双边匹配方案。同时,Chen 等和 Yang 等考虑了患者的预约行为,构建了相应的匹配模型^[16,22]。Yang 等^[22]将双边匹配理论引入医疗专家与患者的预约问题,提出了考虑双方主体公平性的均衡匹配模型。Chen 等^[16]提出了一种考虑患者预约行为的匹配决策方法。此外,还有部分学者考虑了基于主体心理行为的双边

匹配模型^[4,23]。例如,Gao等^[4]根据患者的个性化需求的类型,计算对医生的满意度矩阵,构建匹配决策模型;Chen等^[23]则考虑了决策主体的犹豫心理,通过比较各指标的期望水平和评价信息之间的差异度,来计算相应的满意度矩阵。可以看到,上述方法为医患匹配提供了重要借鉴,但还存在一定的缺陷:(1)未考虑到患者的风险规避态度,缺乏对患者心理行为的描述;(2)未考虑到患者需求的优先性,具有一定的局限性。因此,本文在考虑患者需求优先性和风险态度的情况下,提出了一个多阶段匹配模型来解决医患匹配问题。

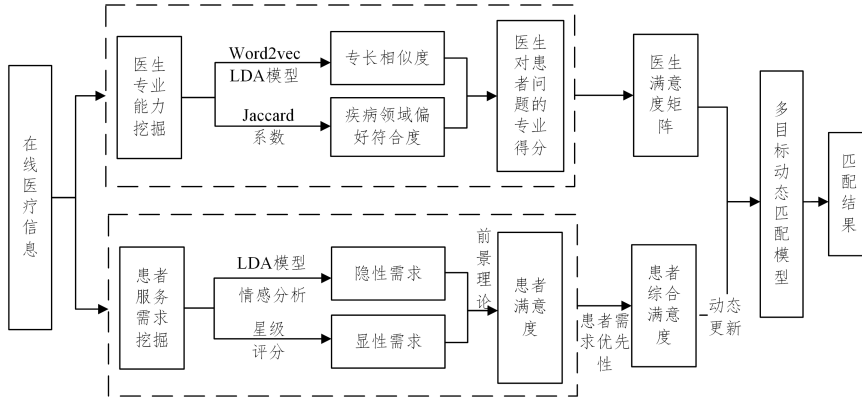


图1 研究框架图

Fig. 1 Research framework

3.1 医生服务能力挖掘

由于医疗服务的关键在于缓解病痛,而专业能力直接影响医疗服务的质量,因此从专长相似度和疾病领域偏好两个角度来描述医生的服务能力。为方便起见,令患者集合为: $P = \{P_1, P_2, \dots, P_m\}$, 其中 P_i 表示第 i 位患者, $i = 1, 2, \dots, m$ 。医生集合为 $D = \{D_1, D_2, \dots, D_n\}$, 其中 D_j 代表第 j 位医生, $j = 1, 2, \dots, n$ 。

3.1.1 专长相似度

对于专长相似度,本文在文献[3]的基础上,采取Word2Vec方法,针对用户咨询文本,从相似患者和相似医生两个角度来计算相似度得分。

首先,利用Word2Vec向量化表示目标患者咨询文本 d_i 和所有咨询文本 d_q ,再根据余弦相似度来计算两者的相似度,即:

$$sim_1(d_i, d_q) = \frac{d_i \cdot d_q}{\|d_i\| \times \|d_q\|} \quad (1)$$

我们选取相似度排名前 K 条咨询文本,形成相似患者集合 V_1 。

随后,通过主题模型挖掘医生历史咨询文本中的隐含疾病主题。每个主题代表一类疾病,每类疾病下有该疾病患者的咨询文本,它们分属于不同的就诊医生。由于一个医生会接诊多个患者,因此其所接诊的患者疾病类型也有所不同,即医生被分属到不同的疾病类型中。每个主题下的医生概率不同,也代表了医生擅长领域的不同。对于集合 V_1 中的每个相似患者,其咨询文本都属于某一主题。在该主题下,计算该文本与其余文本的分布相似度,得到其相似医生集合 V_2 ,相似度

3 考虑患者需求优先性的医患匹配方法

在考虑患者需求优先性的医患匹配决策问题中,主要包括患者、医生和在线问诊平台三方。其中,患者和医生为参与匹配的主体,在线问诊平台为决策者。为了帮助在线问诊平台进行决策,本文首先从在线医疗信息中挖掘患者需求和医生服务信息,据此对双方进行评价。其次,在考虑患者需求优先性和风险态度的情况下,提出了一个多阶段匹配模型来帮助在线问诊平台进行医患匹配决策。本文提出的医患匹配方法的研究框架如图1所示。

$sim_2(P, Q)$ 的计算式如下:

$$D_{KL}(P \parallel Q) = \sum_{x \in X} P(x) \log \frac{P(x)}{Q(x)}$$

$$D_{KL}(P \parallel |Q|) = \frac{1}{2} D_{KL} \left(P \parallel \frac{P+Q}{2} \right) + \frac{1}{2} D_{KL} D_{KL} \left(Q \parallel \frac{P+Q}{2} \right)$$

$$sim_2(P, Q) = \frac{1}{1 + D_{KL}(P \parallel |Q| * n)} \quad (2)$$

其中, P 和 Q 表示医生 D_j 和 D_q 的主题分布, n 为调节因子。故而,对于患者 P_i 有相似患者 P_j , 其中相似患者 P_j 对应的就诊医生为 D_j 。那么,同一主题下的医生 D_j 与患者 P_i 的相似度得分为:

$$sim(P_i, D_j) = sim_1(d_i, d_q) * sim_2(P, Q) \quad (3)$$

对于医生 D_j , 患者 P_i 的专业相似度得分为 $sim(P_i, D_j)$ 。由此可获取患者 P_i 在医生 D_j 的专长相似度下的满意度矩阵:

$$v_{sim} = [sim(P_i, D_j)]_{m \times n} \quad (4)$$

3.1.2 疾病领域偏好

除了专长相似度,疾病领域偏好也是描述医生服务提供能力的重要指标。由于每个医生都拥有大量的历史咨询文本,咨询文本中又包含了患者的疾病信息,因此本文基于医生历史咨询文本挖掘医生疾病领域偏好。杰卡德系数用于比较两个集合的相似性,相似性越高则两集合的共有元素占比越大。已有研究将杰卡德系数用于消费者对品牌属性的偏好研究^[24]。考虑到咨询文本中包含疾病标签,因此可以利用杰卡德系数来探究医生的疾病领域偏好,其计算式如下:

$$Jaccard_j^{dt} = \frac{a}{H1 + H2 - a} \quad (5)$$

其中, $Jaccard_j^{ill}$ 表示医生 D_j 在疾病 ill 上的领域偏好, a 为医生 D_j 历史咨询文本中包含疾病 ill 的咨询文本次数; $H1$ 是医生 D_j 所有历史咨询文本次数; $H2$ 是包含疾病 ill 的咨询文本在整个咨询文本集中出现的次数。

由于每位待诊患者都有相应的咨询文本和疾病标签, 对于每位医生来说, 患者的疾病标签越符合医生的疾病领域偏好, 对该患者问题的解答就更有把握。因此通过计算患者的疾病领域偏好符合度, 来描述医生的服务提供能力, 其计算式如下:

$$Jaccard(P_i, D_j) = \frac{\sum^{ill} Jaccard_j^{ill}}{|I|} \quad (6)$$

其中, $Jaccard(P_i, D_j)$ 表示患者 P_i 对于医生 D_j 的疾病领域偏好符合度, $|I|$ 表示患者 P_i 的疾病标签总数, I 表示患者 P_i 的疾病标签集。由此可获取患者 P_i 在医生 D_j 的领域偏好下的满意度矩阵。

$$v_{jacc} = [Jaccard(P_i, D_j)]_{m \times n} \quad (7)$$

综上所述, 我们在本文中使用的专长相似度和疾病领域偏好符合度来表示医生的服务提供指标。

3.2 患者服务需求挖掘

本节主要从医生隐性特征和医生显性特征两个角度出发, 挖掘患者需求。首先, 利用机器学习方法从评论文本中挖掘患者的隐性服务需求, 同时考虑其对星级评分等显性特征的需求, 构成患者的服务需求评价指标。其次, 利用情感分析工具, 计算每个隐性评价指标的得分。最后, 考虑到患者的风险态度, 引入前景理论计算患者需求满意度。为方便起见, 令患者需求为 $C = C_d \cup C_r = \{C_1, C_2, \dots, C_f, \dots, C_h\}$, 其中 C_d 表示显性需求集合, C_r 表示隐性需求集合。

3.2.1 基于评论文本的患者需求挖掘

LDA 是一种生成式统计模型, 可用于从大量评论中提取主题。在 LDA 中, 每条评论都可以被视为各种主题的混合, 其中每个主题是一组代表某些“意义”的单词, 表示一个概念或问题的某一方面^[25]。基于此, 利用 LDA 方法挖掘需求主题, 并基于获得的主题分布和词语分布, 来推断患者的隐性需求。由于需求主题中含有大量的噪声词, 我们通过对主题进行手动处理, 来获得一组带主题标签(隐性需求)和与该主题标签(隐性需求)相关的词语集合, 并将其作为患者的需求词典。

一般来说, 一条在线评论可能包含多个句子, 涉及患者对不同服务需求的评价。为了识别患者对该医生在不同服务需求下的情感强度, 需要从在线评论中抽取与每个需求相关的短句子。首先, 依据需求词典, 定位需求词语所在位置; 再寻找距离最近的标点符号, 提取出短句 r 。由此, 可将每条在线评论划分为若干个包含不同需求词语的短句。接着利用情感分析工具, 可得到医生 D_j 包含需求 C_f 的评论短句 r 的情感得分 $senti_{jr}^f$ 。假设 Per_j^f 表示医生 D_j 在需求 C_f 上的表现, 其计算式如下:

$$Per_j^f = \frac{\sum_{r=1}^R senti_{jr}^f}{R} \quad (8)$$

其中, R 代表医生 D_j 包含需求 C_f 的评论短句 r 的总数, $C_f \in C_r$ 。由此, 我们可得到患者对医生的定性需求得分矩阵。

$$q_{ijf} = [Per_j^f]_{m \times n}, C_f \in C_r \quad (9)$$

3.2.2 基于前景理论的患者满意度

在线问诊平台中, 患者提出问题的同时, 常常会对候选医生会有一个心理预期。如医生职称, 往往希望职称越高越好。基于此, 引入前景理论来刻画患者对医生的偏好, 并将偏好转化为方便量化的满意度指标。

对于需求 $C = \{C_1, C_2, \dots, C_f, \dots, C_h\}$, 有需求 C_f 下的得分矩阵 $[q_{ijf}]_{m \times n}$ 。考虑到需求得分通常不属于同类标度, 我们使用 $\frac{q_{ijf} - \min_i q_{ijf}}{\max_i q_{ijf} - \min_i q_{ijf}}$, $\frac{\max_i q_{ijf} - q_{ijf}}{\max_i q_{ijf} - \min_i q_{ijf}}$ 来归一化处理效益型和成本型特征。

在前景理论中, 个体的损失和收益是通过备选项与价值参考点之间的对比得到的。在实际就诊过程中, 患者对于需求有一个最低可接受的心理阈值, 如果超过该阈值则患者获得收益, 反之则有损失, 故而该阈值可作为衡量价值的参考点。为了方便理解, 我们使用 $DS = (r_{ijf})_{m \times n \times h} = (s_{ijf})_{m \times n}$ 来表示参考矩阵, 其中 s_{ijf} 表示患者在需求 C_f 下的参考点。对于患者 i , 其收益矩阵 $\gamma = [\gamma_{ijf}]_{m \times n \times h}$ 和损失矩阵 $\phi = [\phi_{ijf}]_{m \times n \times h}$ 的计算式如下:

$$\gamma_{ijf} = \begin{cases} q_{ijf} + 1 - r_{ijf}, & q_{ijf} \geq r_{ijf} \\ 0, & q_{ijf} < r_{ijf} \end{cases} \quad (10)$$

$$\phi_{ijf} = \begin{cases} 0, & q_{ijf} \geq r_{ijf} \\ r_{ijf} - q_{ijf}, & q_{ijf} < r_{ijf} \end{cases} \quad (11)$$

进一步地, 考虑到患者对收益和损失的不同风险态度, 引入前景理论来计算收益和损失的效用值。

$$\begin{cases} \epsilon_{ijf}^+ = (\gamma_{ijf})^\alpha, & 0 < \alpha < 1 \\ \epsilon_{ijf}^- = -\theta(\phi_{ijf})^\beta, & 0 < \beta < 1, \theta > 1 \end{cases} \quad (12)$$

其中, α 和 β 为风险态度系数, 分别表示收益和损失值函数的凸度和凹度。一般而言, α 和 β 的值越大, 相应的收益和损失值函数的凹凸度就越大, 这表明患者更倾向于承担风险。 θ 是损失规避系数, $\theta > 1$ 表明相较于收益, 患者对损失更加敏感, θ 越大, 损失厌恶程度就越大。参考文献[26-27], 将相关系数定为 $\alpha = \beta = 0.88, \theta = 2.25$ 。因此, 患者的需求满意度矩阵为 $[\epsilon_{ijf}]_{m \times n}$, 其计算式如下:

$$\epsilon_{ijf} = \epsilon_{ijf}^+ + \epsilon_{ijf}^- \quad (13)$$

3.3 多阶段医患匹配方法

为了综合描述患者需求, 我们需要进一步对患者需求进行加权。一般而言, 多准则决策问题都是采用线性加权的方法, 在该种方法下, 不同属性之间存在相互补偿的特点。但是在实际决策过程中, 不同需求对患者的重要程度是不同的, 在这种情况下线性加权无法完成效用补偿。因此, 本文考虑了患者的需求优先性。为方便表示, 令患者需求优先性为 $G = [G_1, \dots, G_f, \dots, G_h]^T$ 。其中, $G_f \in \{1, 2, \dots, l, \dots, k\}, l \in \{1, 2, \dots, k\}, G_f$ 代表需求 C_f 优先级。

根据患者需求优先级, 将匹配过程分为 k 个阶段, 每阶段根据需求优先级实时更新需求权重。具体而言, 在每一阶段患者会提供一些需求信息, 以进行匹配。若匹配成功, 则患者

接受就诊服务;若匹配失败,患者则可能选择更新需求,进入下一阶段,以保证尽快匹配;或者放弃匹配,选择继续等待。

该过程将一直持续,直到医患双方无法满足匹配条件为止。上述动态匹配流程图如图2所示。

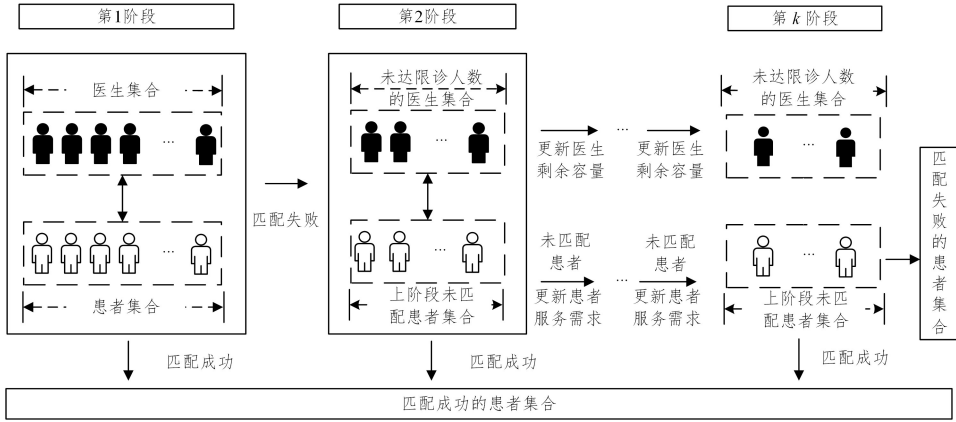


图2 动态匹配流程图

Fig. 2 Multi-stage dynamic matching

3.3.1 权重计算

根据 Yager^[28]的思想,下级特征的权重应由上级特征的效用值的乘积决定。基于满意度矩阵和需求优先级矩阵,我们可以计算出患者 P_i 优先级为 l 的需求的效用值的乘积 U_i^l :

$$U_i^l = \left(\prod_{j=1}^n (|\text{mean}(\epsilon_{ijf^1})| \times \dots \times |\text{mean}(\epsilon_{ijf^{l-1}})|) \right)^{1/n} \quad (14)$$

其中, U_i^l 表示优先级为 l 的效用值的乘积, $l \in \{1, \dots, k\}$ 。特别地,当 $l=1$ 时, $U_i^1=1$ 。 ϵ_{ijf^1} 和 $\epsilon_{ijf^{l-1}}$ 分别表示优先级为1和 $l-1$ 的满意程度; $\text{mean}(\epsilon_{ijf^1})$ 和 $\text{mean}(\epsilon_{ijf^{l-1}})$ 分别表示优先级为1和 $l-1$ 的需求的满意度的平均值。由此可得患者 P_i 的归一化权重为:

$$\omega_i^l = \frac{U_i^l}{\sum_{l=1}^k U_i^l} \quad (15)$$

其中, ω_i^l 表示患者 P_i 优先级为 l 的需求归一化权重,则所有患者的权值矩阵为 $\mathbf{w}^p = [\omega_1^1, \omega_1^2, \dots, \omega_1^k, \dots, \omega_m^1, \dots, \omega_m^k]_{m \times k}$ 。

3.3.2 综合满意度

根据患者需求优先级,将决策过程划分为 k 个阶段。对于第一阶段,只考虑优先级为1的属性,因为这些属性对患者和医生来说是最重要的属性,只要满足了这些属性,匹配就会成功。因此,第一阶段的患者综合满意度 $\mathbf{P}^1 = [\alpha_{ij}^1]_{m \times n}$ 的计算式如下:

$$\alpha_{ij}^1 = \text{mean}(\epsilon_{ijf^1}) \quad (16)$$

在后续阶段中,我们将继续匹配未匹配的患者。需要注意的是,第 l 阶段的患者综合满意度 $\mathbf{P}^l = [\alpha_{ij}^l]_{m' \times n'}$ 不仅受优先级为 l 的需求的影响,还受更高优先级的需求的影响。基于此,考虑到当优先级小于 l 时这些主体不匹配,因此主要关注优先级为 l 的属性。在这种情况下,将权重反推,其综合满意度的计算式如下:

$$\alpha_{ij}^l = \text{mean}(\epsilon_{ijf^1}) \times \omega_i^1 + \text{mean}(\epsilon_{ijf^2}) \times \omega_i^{l-1} + \dots + \text{mean}(\epsilon_{ijf^l}) \times \omega_i^l \quad (17)$$

由此,可得到第 l 阶段的患者综合满意度 $\mathbf{P}^l = [\alpha_{ij}^l]_{m' \times n'}$,其中 m' 和 n' 表示参与第 l 阶段匹配的患者和医生的数量, $l \in \{1, 2, \dots, k\}$ 。

医生服务提供满意度主要是根据患者病情特点与医生

专业能力的匹配程度来衡量的。由于患者病情和医生专业能力在短时间内不会发生变化,因此我们用指标平均值来表示医生对患者的综合满意度 $\mathbf{D} = [\beta_{ij}]_{m \times n}$ 。根据第3.1节的医生服务提供指标,其计算式如下:

$$\beta_{ij} = \text{mean}(\mathbf{v}_{\text{sim}} + \mathbf{v}_{\text{jacc}}) \quad (18)$$

进而,可得到第 l 阶段的医生综合满意度 $\mathbf{D}^l = [\beta_{ij}^l]_{m' \times n'}$ 。

3.3.3 多阶段医患匹配模型

在满意度矩阵的基础上,我们假设 x_{ij} 是一个0~1变量。如果 $x_{ij}=0$,则意味着 P_i 和 D_j 不匹配;如果 $x_{ij}=1$,则表示 P_i 和 D_j 匹配。具体而言,优化模型(模型I)可构造为:

$$\max Z_p' = \sum_{i=1}^{m'} \sum_{j=1}^{n'} \alpha_{ij}^l x_{ij} \quad (19)$$

$$\max Z_b' = \sum_{i=1}^{m'} \sum_{j=1}^{n'} \beta_{ij}^l x_{ij} \quad (20)$$

$$\text{s. t. } \sum_{i=1}^{m'} x_{ij} \leq b' \quad (21)$$

$$\sum_{j=1}^{n'} x_{ij} \leq c' \quad (22)$$

$$x_{ij} = 0 \text{ or } 1 \quad (23)$$

其中, m' 和 n' 分别是第 l 阶段参与匹配的患者和医生数量, b' 为第 l 阶段患者问题的剩余可分配量, c' 为第 l 阶段医生的剩余接诊量。目标函数(19)和(20)表示最大化患者和医生满意度,约束(21)表示一个患者问题的分配量不可超过其最大可分配量,约束(22)表示医生接诊患者不能超过其最大接诊量。

为了求解模型I,采用线性加权法对两个目标函数(19)和(20)进行加权。假设 ω_p 和 ω_D 分别表示目标函数 Z_p' 和 Z_b' 的权重,其中 $0 \leq \omega_p \leq 1, 0 \leq \omega_D \leq 1, \omega_p + \omega_D = 1$ 。据此,将模型I转化为单目标0-1规划模型,即模型II。优化模型(模型II)构造为:

$$\max Z' = \omega_p \alpha_{ij}^l x_{ij} + \omega_D \beta_{ij}^l x_{ij} \quad (24)$$

$$\text{s. t. } \sum_{i=1}^{m'} x_{ij} \leq b' \quad (25)$$

$$\sum_{j=1}^{n'} x_{ij} \leq c' \quad (26)$$

$$x_{ij} = 0 \text{ or } 1 \quad (27)$$

通过求解模型II,我们可以按照优先级 $1-k$ 的顺序,逐层求解优化模型,得到匹配结果。

3.3.4 匹配流程

根据第 3.1—3.3 节的分析,可以给出考虑需求优先性的在线医患双边匹配方法的具体步骤,其详细过程如下。

Step1 按照第 3.1 节的方法,可以挖掘到医生 D_j 对患者 P_i 的服务提供评价得分 $v_{sim} = [sim(P_i, D_j)]_{m \times n}$ 和 $v_{jacc} = [Jaccard(P_i, D_j)]_{m \times n}$ 。

Step2 按照第 3.2.1 节的方法,可以挖掘得到患者的隐性需求集合 C_r ,以及相应的隐性需求得分 $q_{ijf} = [Perf]_{m \times n}$, $C_f \in C_r$ 。

Step3 通过融合显性需求集合 C_d ,得到患者需求集合 $C = \{C_1, C_2, \dots, C_f, \dots, C_h\}$,以及相应的得分矩阵 $[q_{ijf}]_{m \times n}$ 。根据第 3.2.2 节的计算规则,获得患者 P_i 对医生 D_j 在需求 C_f 下的满意度矩阵 $[\epsilon_{ijf}]_{m \times n}$ 。

Step4 根据式(14)、式(15)计算患者权重矩阵 $w^p = [w_1^p, w_2^p, \dots, w_f^p, \dots, w_h^p]_{m \times k}^T$ 。

Step5 考虑需求优先级,按照第 3.3.2 节的方法计算各阶段患者和医生的综合满意度矩阵 $P' = [\alpha_{ij}^p]_{m' \times n'}$, $D' = [\beta_{ij}^p]_{m' \times n'}$,同时根据需求优先级构建多阶段动态匹配模型。

Step6 求解模型 II 获得双边匹配方案。

4 算例分析

为了验证本文所提推荐方法的有效性,本文从好大夫在线网站(haodf.com)上爬取了 2016—2020 年内科科室的用户咨询文本、用户评论和医生简介等原始数据。由于内科科室种类繁多,本文选择了消化内科、心血管科、内分泌科和变态反应科这 4 个科室作为研究对象,爬取上述科室(包括子科室)中的咨询文本、用户评论、医生简介和推荐热度等数据。经过数据清洗后,保留了 101 925 条咨询文本、396 位医生以及 19 888 条评论,并通过统计分析得到内科的 88 个疾病标签。为了方便起见,我们从咨询文本中抽取 300 条属于不同患者的文本作为服务需求方,将清理得到的 396 位医生作为服务提供方。

4.1 特征挖掘

本节抽取 80% 的咨询文本作为医生历史咨询文本训练集,用于 Word2Vec 模型的训练、专长相似度和疾病领域偏好符合度的计算,将剩下 20% 的咨询文本作为测试集。参考已有文献和专家建议,我们将主题数确定为 4,分别为医生态度^[29-31]、专业技能^[5,16,29]、治疗效果^[5,16]和医院秩序^[5,30-31]。每个主题的需求词语词典如表 1 所列。

表 1 需求词典

Table 1 Demand dictionary

主题	关键词
医生态度	热情、和蔼可亲、细心、负责、细致、仔细、亲切、服务态度、耐心、温柔
专业技能	医技、技艺、精湛、专业、高超、高明、医术、技术、能力、擅长
治疗效果	结果、好转、效果、解决、诊断、用药准确、痊愈、改善、明显好转、疗效
医院秩序	医院、就诊、时间、挂号、方便、门诊、复诊、预约、等待时间、回复

此外,为了对医生进行综合评价,我们考虑了由患者和

haodf.com 平台提供的标签,构成患者的服务需求评价指标集合,如表 2 所列。值得一提的是,由于技术职称代表了医生在该领域的专业水平和经验等综合素质,因此我们使用其作为 c_1 的评价特征。特征 c_2, c_3, c_5, c_7 取值按照第 3.2.1 节中的流程计算得到。此外,我们用医生服务患者的数量来表征特征 c_4 ;用医生收到的礼物来刻画特征 c_6 ;特征 c_8 可从平台直接获取。

表 2 患者需求

Table 2 Patient demands

特征	含义	类型	文献
c_1	职称	效益(定量指标)	[29-32]
c_2	专业技能	效益(定性指标)	[5,16,29]
c_3	治疗效果	效益(定性指标)	[5,16]
c_4	经验	效益(定量指标)	[29-30]
c_5	医生态度	效益(定性指标)	[29-31]
c_6	个人成就	效益(定量指标)	[5,32]
c_7	医院秩序	效益(定性指标)	[5,30-31]
c_8	推荐热度	效益(定量指标)	[5,31]

4.2 实验结果分析

为了验证匹配结果的科学性和合理性,首先采用 4 个评价指标,用于衡量匹配结果的准确性和多样性。其次,通过与 3 种基准算法的比较分析,来验证本文方法的有效性。最后,考虑到目标函数参数 w_p 和 w_D 对结果的影响,进行了相应的敏感性分析。在实验过程中,假设医生最大接诊问题数为 4,一个患者问题最多分配给 5 位医生,匹配阶段 $k=3$ 。

4.2.1 评价指标

为了验证本文方法在提高匹配准确度和多样性上的优势,我们使用 4 个指标来评估模型,分别是匹配精度、平均精度、匹配覆盖率和新颖性。

1)匹配精度。由于患者本身缺乏专业知识,患者实际就诊的医生并不一定能够满足患者的专业需求,因此选择回答过该问题的医生作为准确医生列表。具体计算式如下:

$$Accuracy = \frac{\sum_{i=1}^P |Acc_{list}^i \cap Match_i|}{\sum_{i=1}^P |Match_i|} \quad (28)$$

其中, P 代表患者集合, Acc_{list}^i 代表患者 P_i 的准确医生列表, $Match_i$ 代表患者 P_i 匹配的医生列表, $|Match_i|$ 代表患者 P_i 匹配的医生人数。

2)平均精度。平均精度反映了模型给患者匹配正确医生排名的能力,平均精度越高,最终匹配的医生列表中准确医生的排名就越靠前,其计算式如下:

$$AP(i) = \frac{1}{|X|} \sum_{x=1}^X \frac{x}{position(x)}$$

$$MAP = \frac{\sum_{i=1}^P AP(i)}{|P|} \quad (29)$$

其中, $position(x)$ 表示匹配正确的医生在推荐列表中的位置,若没有匹配正确,则患者 $AP(i)=0$, $|X|$ 表示匹配准确的医生人数。

3)匹配覆盖率。为了评估医生匹配成功的比例,我们使用覆盖度来描述,具体计算式如下:

$$Coverage = \frac{|Match_{list}^D|}{|D|} \quad (30)$$

其中, $Match_{list}^D$ 代表被匹配的医生人数, $|D|$ 代表医生总人数。

4) 新颖性。新颖性原是一种用于衡量推荐系统中推荐不太受欢迎物品的能力的指标^[33]。这里用它来评价匹配模型中匹配不太受欢迎的医生的能力的指标。医生 D_j 的受欢迎程度用 IP_{D_j} 来表示:

$$IP_{D_j} = \frac{|rec_j|}{|rec|} \quad (31)$$

其中, rec_j 代表平台给予的医生 D_j 的热度。由于平台热度为五分制, 故而 $rec=5$ 。相应地, 患者 P_i 匹配结果的新颖性的计算式如下:

$$INV_i = \frac{\sum_{D_j}^{Match_i} IP_{D_j}}{|Match_i|} \quad (32)$$

由此, 整体匹配结果的新颖性的计算式如下:

$$INV = \frac{\sum_i^P INV_i}{|P|} \quad (33)$$


4.2.2 敏感性分析

根据第 3.3.3 节的分析, 模型 I 和模型 II 中目标函数的参数 w_P 和 w_D 会影响最终的匹配结果。为了研究其对双边匹配的影响, 令 w_D 的取值分别为 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8。由于 $w_P + w_D = 1$, 则 w_P 的取值分别为 0.8, 0.7, 0.6, 0.5, 0.4, 0.3, 0.2。当 w_P 和 w_D 取不同数值时, 相应的匹配结果分别如表 3 和图 3 所示。


表 3 敏感性分析

Table 3 Sensitivity analysis


w_D	w_P	第 1 阶段 匹配成功 的患者数	第 2 阶段 匹配成功 的患者数	第 3 阶段 匹配成功 的患者数	匹配 成功的患者 总人数	最优值
0.2	0.8	395	561	350	1306	309.3939
0.3	0.7	532	669	186	1387	288.3191
0.4	0.6	919	439	84	1442	269.1254
0.5	0.5	1080	336	56	1472	319.9781
0.6	0.4	1312	152	14	1478	364.6267
0.7	0.3	1438	47	6	1491	460.1738
0.8	0.2	1494	3	1	1498	575.5133




(a) 匹配精度对比



(b) 平均精度对比



(c) 覆盖率对比



(d) 新颖性对比

图 3 敏感性分析

Fig. 3 Sensitivity analysis

从表 4 中可以看出, 随着 w_D 的增大, 在第一阶段匹配的患者数量增加, 患者匹配的总数量也增加。这主要是因为患者端目标函数代表了患者对医生的偏好, 随着 w_P 的降低, 患者对医生的条件也逐步放宽, 因此有更多的医生被患者允许进行匹配。

表 4 对比实验分析

Table 4 Comparative analysis

方法	精度	平均精度	覆盖率	新颖性
OSM	0.8209	0.7633	0.9520	0.3496
QM- w^P	0.7655	0.7077	0.9874	0.3643
QM- w^D *	0.7991	0.7432	0.9899	0.3605
MSM	0.8218	0.7792	0.9874	0.3569

从图 3(a) 可以看出, 当 $w_D \leq 0.5$ 时, 匹配准确率呈现可以下降趋势, 但当 $w_D > 0.5$ 时, 匹配准确度出现明显波动。

由此看出医生专业能力对提高匹配准确率有着重要作用, 同时患者需求偏好也会在一定程度上影响匹配的准确率。对于图 3(a) 和图 3(b), 当 $w_D \leq 0.5$ 时, 准确率下降, 平均精度却比较稳定, 这说明患者需求在一定程度上可以保证在第一阶段得到成功匹配。进一步地, 对于图 3(c) 和图 3(d), 可以得到: 随着 w_D 的增大, 匹配覆盖率和新颖性都有所提升。究其原因, 当 w_D 较低时, w_P 会相对较高。考虑到患者缺乏专业知识, 在选择医生时会更倾向于选择热门医生, 致使匹配多样性和新颖性不高, 这也间接说明了挖掘医生专业能力的重要性。最后, 考虑到医疗服务的特殊性, 我们认为医生端目标函数应具有更高的权重, 据此设置 $w_D = 0.8$, $w_P = 0.2$ 。

4.2.3 对比实验

为了进一步说明本文方法的有效性, 我们将本文方法 (Multi-stage Matching, MSM) 与一阶段的双边匹配方法

(One-stage Matching, OSM)和 Qiu 等^[34]的提出方法进行了比较,并结合本节的算例进行对比实验分析。为了融合文献[33]所提出的方法,需要对患者需求进行线性加权。本文采用了两种权重来进行比较:1)本文计算得到的患者权重矩阵 w^p ,该方法命名为 QM- w^p ;2)在本文权重计算方法的基础上,结合 Qiu 等计算得到的效用值,得到新的患者权重矩阵 w^{p^*} ,命名为 QM- w^{p^*} 方法。根据第 4.2.2 节的分析,当 $w_D=0.8$, $w_P=0.2$ 时,相应的实验结果如表 4 所列。


从表 4 中可以看出,本文方法在精度和平均精度上都表现得更为突出。相比 OSM 方法,MSM 方法在 4 个指标上都表现更优。虽然 QM- w^p 和 QM- w^{p^*} 方法在新颖性和覆盖率上表现稍好,但在精度和平均精度上却比 MSM 方法相差甚远。受专业能力所限,过于追求新颖性和匹配医生的覆盖率,也可能导致部分不符合要求的医生匹配到患者。综上所述,本文方法在保证匹配准确度的同时,在一定程度上提高了新医生被发现的可能性,这为匹配结果提供了更多的可能性,也部分缓解了在线问诊平台新医生难以被发现和关注、热门医生超负荷的问题。因此考虑需求优先性的多阶段医患匹配方法是合理且有效的。

结束语 本文基于 haodf.com 的数据,提出了一种考虑患者需求优先性的多阶段医患匹配方法,并通过好大夫内科科室的真实数据对所提方法进行了验证。首先,考虑到医生专业能力的多粒度性,引入了粒计算思想,从病情相似度和疾病领域相似度两个角度来挖掘医生的专业能力,以评估医生提供服务的能力。其次,利用机器学习方法从评论文本中挖掘患者的定性服务需求,同时考虑其对星级评分等定量特征的需求,构成患者的服务需求评价指标,并进一步利用情感分析工具计算得到每个指标的得分。然后,考虑到患者强烈的风险规避态度和患者服务需求优先性,引入前景理论,利用有序加权的方法计算得到患者对医生的满意度,并据此进行多阶段医患匹配。最后,基于好大夫内科科室的真实数据,从准确性、匹配平均精度、匹配覆盖率和新颖性 4 个指标对本文方法进行了比较分析,验证了本文方法在提高匹配准确性和多样性上的有效性,这为在线问诊平台医患匹配问题提供了新的思路。在后续研究中,会进一步探索将深度学习的技术引入在线医患双边匹配过程中,通过数据处理和分析,将多源医生特征进行融合,挖掘医生的多粒度特征,以增强医患双边匹配的可解释性。

参 考 文 献

- [1] WEN C, HSU, LI C, et al. A Novel Recommendation System for Dental Services Based on Online Word-of-Mouth[J]. Information Resources Management Journal, 2017, 30(1): 30-47.
- [2] ZPFA B, GML A, YANG L A. Processes and methods of information fusion for ranking products based on online reviews: An overview[J]. Information Fusion, 2020, 60: 87-97.
- [3] MENG Q Q, XIONG H X. Doctor Recommendation Based on Online Consultation Text Information[J]. Information Science, 2021, 39(6): 152-160.
- [4] GAO Y X, DU Y P, SUN B Z, et al. Matching Method for Medical Service Considering the Personalized Demand of Patients[J]. Operations Research and Management Science, 2019, 28(4): 17-25.
- [5] LIU F, LIAO H C, AL-BARAKATI A. Physician selection based on user-generated content considering interactive criteria and risk preferences of patients[J]. Omega, 2023, 115(C): 102784.
- [6] KOWALSK I. Patients' written reviews as a resource for public healthcare management in England [J]. Procedia Computer Science, 2017, 113: 545-550.
- [7] LI C Y, ZHAI S S, ZHENG L. Measurement of Information demand characteristics in online health community: an empirical analysis based on time and theme perspective[J]. Digital Library Forum, 2016, 148: 34-42.
- [8] GRABNER-KRUTER S, WAIGUNY M K. Insights Into the Impact of Online Physician Reviews on Patients' Decision Making: Randomized Experiment[J]. Journal of Medical Internet Research, 2015, 17(4): e93.
- [9] ABIRAMI A M, ASKARUNISA A. Sentiment analysis model to emphasize the impact of online reviews in healthcare industry [J]. Online Information Review, 2017, 41(4): 471-486.
- [10] GODAGER G. Birds of a feather flock together: A study of doctor-patient matching [J]. Journal of Health Economics, 2012, 31(1): 296-305.
- [11] AGARWAL A K, WONG V, PELULLO A M, et al. Online reviews of specialized drug treatment facilities-identifying potential drivers of high and low patient satisfaction[J]. Journal of General Internal Medicine, 2020, 35(6): 1647-1653.
- [12] AHANI A, NILASHI M, ZOGAAN W A, et al. Evaluating medical travelers' satisfaction through online review analysis [J]. Journal of Hospitality and Tourism Management, 2021, 48: 519-537.
- [13] ALODADI N, ZHOU L. Predicting the helpfulness of online physician reviews [C] // Chicago, IL: Proceedings of the 2016 IEEE International Conference on Healthcare Informatics (ICHI). 2016: 1-6.
- [14] LIU J, ZHANG W, JIANG X, et al. Data mining of the reviews from online private doctors [J]. Telemedicine and E-Health, 2020, 26(9): 1157-1166.
- [15] YE Y, ZHAO Y, SHANG J, et al. A hybrid it framework for identifying high-quality physicians using big data analytics[J]. International Journal of Information Management, 2019, 47: 65-75.
- [16] CHEN X, SUN H, LIANG H M. A Matching Method for Healthcare Service Supply and Demand Considering Patients' Appointment Behavior with Diversified Demand[J]. Operations Research and Management Science, 2019, 28(2): 90-97.
- [17] GALE D, SHAPLEY COLLEGE L. Admissions and the stability of marriage [J]. American Mathematical Monthly, 1962, 69(1): 9-15.
- [18] LE Q. Research on Decision Methods for The Satisfied Two-sided Matching Based on Preference Ordinal Information [D]. Northeastern University, 2011: 16-29.
- [19] CHEN X, ZHAO L, LIANG H M, et al. Matching patients and healthcare service providers: a novel two-stage method based on

- knowledge rules and OWA-NSGA-II algorithm[J]. *Journal of Combinatorial Optimization*, 2019, 37(1): 221-247.
- [20] YUAN D N, JIANG Y P. Stable two-sided matching model between selective operation patients and surgeons[J]. *Systems Engineering-Theory & Practice*, 2019, 39(7): 1752-1762.
- [21] SINGH V K, MUKHOPADHYAY S. Hiring Expert Consultants in E-Healthcare With Budget Constraint[EB/OL]. (2016-10-14) [2018-02-14]. <https://doi.org/10.48550/arXiv.1610.04454>.
- [22] YANG Y, LUO S, FAN J, et al. Study on specialist outpatient matching appointment and the balance matching model[J]. *Journal of Combinatorial Optimization*, 2019, 37(1): 20-39.
- [23] CHEN X, WANG J. Matching Method for Medical Service Supply and Demand Considering Bodies Psychological Behavior Based on Intelligent Platform[J]. *Operations Research and Management Science*, 2018, 27(10): 125-132.
- [24] HU F, TRIVEDI R H. Mapping hotel brand positioning and competitive landscapes by text-mining user-generated content [J]. *International Journal of Hospitality Management*, 2020, 84: 102317.
- [25] QI J Y, ZHANG Z, JEONS et al. Mining customer requirements from online reviews: A product improvement perspective[J]. *Information & Management*, 2016, 53(8): 951-963.
- [26] TVERSKY A, KAHNEMAN D. Advances in Prospect Theory: Cumulative Representation of Uncertainty[J]. *Journal of Risk and Uncertainty*, 1992, 5(4): 297-323.
- [27] LIU S, LIU X, QIN J. Three-way group decisions based on prospect theory[J]. *Journal of the Operational Research Society*, 2018, 69(1): 25-35.
- [28] YAGER R R. Modeling prioritized multicriteria decision making [J]. *IEEE Transactions on Cybernetics*, 2004, 34(6): 2396-2404.
- [29] HU J, ZHANG X, YANG Y, et al. New doctors ranking system based on VIKOR method [J]. *International Transactions in Operational Research*, 2020, 27(2): 1236-1261.
- [30] LU S, RUI H. Can We Trust Online Physician Ratings? Evidence from Cardiac Surgeons in Florida [J]. *Management Science*, 2018, 64(6): 2557-2573.
- [31] DAMODAR D, DONNALLY C J, MCCORMICK J R, et al. How wait-times, social media, and surgeon demographics influence online reviews on leading review websites for joint replacement surgeons [J]. *Journal of Clinical Orthopaedics and Trauma*, 2019, 10(4): 761-767.
- [32] SHUKLA A D, GAO G G, AGARWAL R. How digital word-of-mouth affects consumer decision making: evidence from doctor appointment booking [J]. *Management Science*, 2021, 67(3): 1546-1568.
- [33] RAHMAN I, HOSSEIN A D, YASHAR D N, et al. The role of context fusion on accuracy, beyond-accuracy, and fairness of point-of-interest recommendation systems [J]. *Expert Systems With Applications*, 2022, 205(NOV.): 117700. 1-117700. 13.
- [34] QIU Y, GU D, ZHANG H, et al. Two-stage matching decision-making method in medical service supply chain [J]. *International Journal of Logistics Research and Applications*, 2022, 25(4/5): 623-638.



FAN Tingrui, born in 1999, postgraduate. Her main research interests include data mining, medical operations management, three-way decision and granular computing.



LIU Dun, born in 1983, Ph. D, professor. His main research interests include data mining and knowledge discovery, rough set theory and granular computing, decision support systems.

(责任编辑:喻黎)