

# 基于集成策略的团队医生问诊参与行为预测研究\*

迟晓彤 刘璇 程岩 冯程程  
(华东理工大学 商学院, 上海 200237)

**摘要** 在线医生团队是优质的在线医疗服务提供方。本文聚焦“好大夫在线”平台的在线医生团队,建立分类预测模型以预测团队成员参与在线团队问诊行为。模型构造了静态属性、动态行为和交互文本三类特征集,对比梯度提升决策树、随机森林(random forests)、K近邻(k-nearest neighbor, KNN)和多层感知机(multilayer perceptron, MLP)的表现,使用SHAP(Shapley additive exPlanations,沙普利加和解释)解释特征重要性,并提出基于最佳决策阈值的投票集成策略和基于权重的集成策略来提高模型预测能力。结果显示,团队问诊中的文本特征有助于提升模型预测效果;集成策略表现优于单个分类器,基于最佳决策阈值的投票集成策略表现最优。研究结论对在线医疗的团队管理具有指导意义,有助于优化医疗资源分配。

**关键词** 在线医生团队, 特征工程, 行为预测, 集成策略

**中图分类号** C931.2

## 1 引言

在线健康社区作为一种线上问诊渠道,一方面在一定程度上能够缓解线下医疗资源紧张的问题<sup>[1]</sup>;另一方面能够帮助患者从线上获取各种医疗便利<sup>[2]</sup>,满足相对简单的医疗需求,是对线下问诊的有效补充。在线医生团队是在线健康社区中医生为患者提供问诊咨询的新模式,一个团队由一位领域内知名专家作为领导者和若干位其他医生组成,他们分布在不同地区的医院,通过在线平台共同为患者提供诊疗建议。一般而言,团队的领导者具有较高的专业资本与丰富的经验,并邀请其他科室的医生参与团队,负责团队的整体管理、协调和决策,确保团队的顺利运行。团队成员负责提供在线医疗咨询、诊断、治疗和建议等专业服务,为患者提供多样化的医疗知识以及合适的就医指导。这种形式使得医生资源通过互联网进行重组,有利于充分发挥医生的专业技能,完成复杂的医疗任务,提高治疗效果<sup>[3]</sup>。

在线健康社区中医生的参与可以提高患者的忠诚度,有利于在线健康的可持续发展<sup>[1]</sup>。在线医生团队中,医生积极参与在线团队问诊不仅能够为团队成员之间的知识分享和整合提供更多的机会,还有利于团队整体地位和声誉的提升。目前,在线医生团队仍处于初步发展阶段,由于缺乏明确的分工以及在线医生团队的非正式性,参与团队问诊极大程度依赖于团队成员的自主性。然而,根据“好大夫在线”医疗平台在线医生团队的参与现状可知,尽管许多医生已经加入了在线医生团队,但实际上有相当比例的医生并未实际参与到团队问诊的回复中,医生团队成员的整体参与度亟待提升。如果能够提前预测医生在团队问诊中的参与情况,那么平台以及各团队便能够据此制定更加灵活和前瞻性的管理政策,进而充分发挥在线医生团队的优势并推动在线健康社区的发展。

\* 基金项目:国家自然科学基金面上项目(71971082, 71471064)、上海市“科技创新行动计划”软科学研究项目(22692110200)。  
通信作者:刘璇,华东理工大学商学院,管理学博士,教授,博士生导师, E-mail: xuanliu@ecust.edu.cn。

目前,对于在线医生团队的研究主要聚焦于团队绩效等方面<sup>[4,5]</sup>,虽然有学者关注医生加入团队的过程<sup>[6]</sup>,但对于医生加入团队后,在团队问诊中的参与情况,尚缺乏深入的探讨。因此,本文的研究问题为构建一个有效的模型预测医生在团队问诊中的参与行为。本文期望基于医生和团队的静态特征及历史在线医疗数据,构建有效的行为预测模型,以预测医生在团队问诊中的参与情况,为医生团队及类似的远程医疗团队管理策略提供模型支持。

本文以“好大夫在线”为研究平台,基于团队问诊模块,分别从医生和团队两个层面构造静态属性特征集和动态行为特征集,其中团队特征包括团队整体特征和领导者特征,医生个体特征为基于医生个体的属性和历史在线医疗行为构造的特征,以此对在线医生团队成员在团队问诊中的参与行为进行预测。此外,本文验证了团队问诊交互文本的词汇、句法、语义和语用四种语言风格特征对于参与行为预测的有效性;对比了三种经典的梯度提升树算法 XGBoost<sup>①</sup>、LightGBM<sup>②</sup>、CatBoost<sup>③</sup>,以及随机森林、K 近邻和多层感知机共计六种分类器对在线医生团队成员的参与行为数据集的预测效果;引入 SHAP 计算特征重要性并通过可视化方法增强模型的可解释性;为了提升模型的预测能力,提出基于最佳决策阈值的投票集成策略和基于权重的集成策略,将各分类器的输出结果进行集成。研究结果显示,基于团队问诊记录构造的交互文本特征有助于提升模型预测效果;单个分类器中,LightGBM 模型的表现最优;集成策略的表现优于单个分类器,其中,基于最佳决策阈值的投票集成策略表现最优。本文验证了基于语言风格视角的交互文本特征在行为建模中的关键作用,发现了能够提升在线医生团队成员参与行为预测效果的集成方法,对于在线医生团队的管理具有参考意义,有助于优化医疗资源分配。本文提出的模型不仅能够为现有的在线健康平台提供技术支持,还可以为其他远程诊断团队、远程监护团队的管理提供参考工具,助力其成员参与情况的预测与资源规划。

## 2 文献综述

### 2.1 医生团队相关研究

医生团队是医疗服务中的新型合作模式,医生以多对一的形式为患者提供诊疗服务。学者对医生团队在疾病诊断和治疗中的影响给予了关注。在诊断阶段,具备多学科背景的医生团队成员共同协作能够提升诊断的准确率,例如,多学科医生团队合作培训有助于提升新生儿的生命力和健康状况的评估效果<sup>[7]</sup>;在治疗阶段,团队成员之间的有效协作可以提高治疗的及时性、改善治疗效果<sup>[3]</sup>并降低治疗成本<sup>[8]</sup>,因此,医生团队的建设逐渐受到重视。对于医生而言,加入医生团队可以提升患者对医生的信任<sup>[9]</sup>、提升自身专业能力、促进专业知识和经验的交流与分享。

学者还对医生团队的绩效进行了研究。以往的研究表明,团队成员的多样性<sup>[10,11]</sup>、团队的凝聚力<sup>[12]</sup>、团队互动<sup>[13]</sup>等因素都对团队的绩效或成员的态度产生影响。在医生团队中,团队的结构,如护理人员的重要性<sup>[14]</sup>、有效的领导<sup>[15]</sup>以及医生团队成员间的知识多样性和任务依赖性<sup>[4]</sup>,都有助于提升医生团队的绩效。在个体行为方面,已有研究基于社会影响的视角使用自动逻辑行动者属性模型探讨了医生加入团队的机制,其中,相似的知识背景被认为是驱动医生加入团队的重要因素<sup>[6]</sup>。

---

① eXtreme gradient boosting, 极限梯度提升。

② light gradient boosting machine, 轻量梯度提升机。

③ categorical boosting, 类别梯度提升。

## 2.2 团队参与相关研究

组织中,工作参与代表了员工对工作的态度,通常被定义为个体在心理上认同其工作的程度,反映了个体对工作的重视程度<sup>[16]</sup>。员工积极参与不仅能够提升个人绩效,还有助于保持组织的竞争优势<sup>[17]</sup>。已有研究表明团队工作参与度对于团队绩效有显著影响,学者 Rózewski 等从社交网络的角度研究了知识工作者的合作学习模型,并提出了团队中不同的角色分配的最优策略<sup>[18]</sup>;此外,团队任务和工作参与对知识转移也展现出显著的积极影响<sup>[19]</sup>。

学者对影响团队成员参与团队活动的因素进行了深入研究。首先,成员的参与行为受到个体与其所在组织环境匹配程度的影响,与工作高度匹配的员工更容易在工作中获得成就以及更多的工作自主权<sup>[20]</sup>。其次,团队本身的特点也是影响成员积极性的重要因素。例如,支持性的团队氛围,即充满信任与凝聚力强的团队环境,能够促进团队合作参与,进而提升团队的知识管理水平<sup>[21]</sup>。此外,领导者的风格和特点也能够影响成员的工作态度和工作表现。变革型领导能够提高员工的工作投入,同时降低他们想要离开项目团队的可能性<sup>[22]</sup>;在重症监护团队中,领导者的行为应明确且无歧义,并且能够根据情境需求灵活调整,这种优秀的领导力在提升团队效能和确保患者安全方面发挥着关键作用<sup>[15]</sup>。最后,与领导对成员进行关系差异化对待相比,团队领导与所有成员维持高质量关系的情况可能对团队成员自我效能的发展最为有利<sup>[23]</sup>,从而更容易促使他们主动参与团队工作。

## 2.3 行为预测相关研究

近年来,用户行为预测常见于社交媒体、在线社区等领域。学者通常从用户的静态属性和动态行为两方面选取特征。静态属性特征包括用户的身份、职称、部门等基础信息<sup>[24]</sup>;动态行为特征则捕捉用户在一定时间段内的行为变化,如访问频率、时间间隔等<sup>[25]</sup>,这类特征对行为预测非常关键。在企业信息系统用户异常行为预测模型中,业务特征由于和用户操作相关联,被认为是重要的预测特征<sup>[24]</sup>。

在模型方面,用户行为预测以分类模型为主,其中,多层感知机是一种基本的神经网络模型,擅长处理复杂的非线性问题,其强大的学习能力使其在大规模数据下表现良好,但对参数设置较为敏感。K近邻是一种简单的非参数模型,通过计算样本间距离预测结果,K近邻算法虽然简单,但是在复杂问题中表现出很大的灵活性<sup>[26]</sup>。随机森林通过构建多棵决策树集成预测<sup>[27]</sup>,能够有效处理大规模数据,且对噪声数据具有鲁棒性,但在高噪声数据集上可能出现过拟合。梯度提升决策树模型(如 XGBoost、LightGBM、CatBoost)则在构建决策树的基础上进一步优化,通过加权调整误差提升预测精度。在健康领域行为预测方面,梯度提升决策树在健康应用程序使用行为预测方面得到了良好的表现<sup>[28]</sup>,而随机森林在预测电子健康平台用户退出行为中展现出了出色的预测效果<sup>[29]</sup>。

## 2.4 文献述评

根据上述综述,目前研究中还存在以下不足之处:①提前预测成员的参与行为对及时制定或修改团队的管理策略具有重要意义,能够为团队管理决策提供科学依据。先前的研究主要关注团队成员参与行为的影响因素,关于团队中医生行为的研究仅限于加入医生团队<sup>[6]</sup>,缺乏对团队成员在团队问诊中的参与行为进行预测的深入研究。②在线医生团队与患者的沟通以文本交互为主,而语言风格是健康用户重要的画像特征<sup>[30]</sup>,除了个体的静态和动态特征,还可以探索基于语言风格视角的交互文本特征在算法层

面的结果，以更全面地理解和预测团队成员的参与行为。③各分类器在不同场景各有优劣，目前在在线医生团队成员行为预测方面的表现暂不明晰。

本文旨在构建预测模型，以填补在线医生团队成员行为预测方面的研究空白。在特征构造方面，除了静态属性特征和动态行为特征外，本文将充分考虑医患交互的具体场景，引入语言风格视角，利用医患交互文本构造基于语言风格的交互文本特征，以提升模型的预测性能。此外，本文还将对比不同分类器在该行为预测场景下的表现，并进一步提出集成策略，以进一步优化模型的预测效果。

### 3 研究模型与数据

#### 3.1 研究模型

本文关注在线医生团队中的成员是否参与团队问诊，基于在线医生团队医患交互数据，从团队和个体层面分别提取静态属性特征、动态行为特征以及医生在团队模式下参与问诊的交互文本特征，形成静态属性特征集、动态行为特征集和交互文本特征集，使用 Boruta（基于随机森林的全相关特征选择算法）对特征进行筛选，使用个体分类器基于筛选后的特征进行预测并对比择优，依据 SHAP 值对特征体系进行解释，并提出集成策略进一步提升参与行为预测模型的分类能力，具体研究模型如图 1 所示。

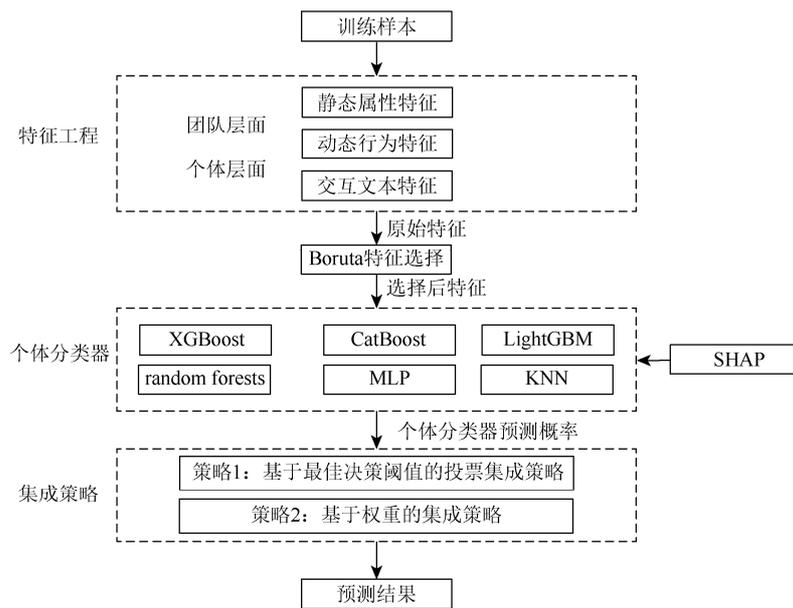


图 1 研究模型

#### 3.2 数据来源

本文的研究问题为预测在线医生团队中的成员是否参与团队问诊，研究对象为已加入在线医生团队的医生，因此从在线医疗咨询平台好大夫在线（www.haodf.com）获取团队成员问诊行为参与相关信息，包括在线医生团队信息、团队成员平台活跃信息（个体层面）以及 2017 年 6 月至 2020 年 4 月团队问诊交互信息，包括医生在团队问诊中发送的文本数据。

### 3.3 数据预处理

本文的预测目标为在线医生团队成员在 2020 年 4 月团队问诊的参与行为，1 表示参与了团队问诊，0 表示未参与团队问诊。在对数据进行统计分析之前，本文过滤掉变量缺失较多的少部分样本，使用平均值和众数对缺失值进行填充。样本包括 872 个在线医生团队，1791 位医生，医生可能由于擅长的专业领域多元化而加入不同的医生团队担任不同的角色，因此得到预测样本共计 2269 个，即医生和团队的组合共计 2269 个。2020 年 2 月和 3 月，样本中参与团队问诊的医生占比分别为 20.10% 和 24.60%，参与度较低。因此，提高医生在团队问诊中的活跃度，对于促进团队问诊模式发展和发挥医疗咨询平台的社会价值具有重要意义。

## 4 特征工程

在对用户行为进行预测时，过去的研究大多从用户静态属性<sup>[24]</sup>和动态行为<sup>[25, 31]</sup>两方面构造特征。本文将从团队层面和医生层面构建静态属性特征集和动态行为特征集，以捕捉医生在平台上的基本特征和行为变化。已有研究表明，语言风格能够显著影响消费者的参与行为<sup>[32]</sup>。在在线医生团队和患者的交互过程中，文本是医患沟通的核心媒介，而语言风格是在健康社区用户的重要画像<sup>[30]</sup>，因此交互文本的语言风格可能成为预测医生参与团队问诊行为的关键特征之一。因此，本文基于在线医生团队信息、团队成员平台活跃信息（个体层面）以及 2017 年 6 月至 2020 年 3 月团队问诊交互信息，共计构造三类特征集：静态属性特征集、动态行为特征集和交互文本特征集。

### 4.1 静态属性特征集 (FS1)

个体和团队相关特征均会影响团队成员参与行为，静态属性特征包括医生个体静态属性 (PS) 和团队整体静态属性 (TS)。医生个体层面的静态属性包括该医生是否为团队领导者、所在医院、所属科室及医生的职称等代表医生地位的变量；团队层面的特征包括团队的服务价格、团队规模以及团队等级的统计特征。由于团队中领导的特点和行为也会影响个体的行为<sup>[22, 33]</sup>，团队领导者的静态属性也被作为团队层面的重要特征 (LS)，为了和团队整体静态属性加以区分，团队领导者静态属性单独列为一类，包括其所在医院、所在科室和职称。

以上静态属性特征构成静态属性特征集，记为 FS1，具体所含特征如表 1 所示。

表 1 静态属性特征集 FS1

	特征类型 (数值/编码)	特征说明
医生静态属性 (PS)	布尔型	是否为团队领导者
	One-hot (独热编码)	医生所在医院 医生所在科室 医生职称
团队静态属性 (TS)	数值型	团队服务价格 团队规模 团队等级统计特征, 包括团队成员所在医院等级、所在城市等级、职称等级的最大值、最小值、平均值和标准差

续表

	特征类型（数值/编码）	特征说明
团队领导者静态属性（LS）	One-hot	团队领导者所在医院 团队领导者所在科室 团队领导者职称

## 4.2 动态行为特征集（FS2）

在构建行为预测模型时，基于历史数据构造的动态特征往往是不可或缺的预测变量，在消费信贷风险预测模型中，消费者的动态消费数据是预测信用卡违约行为的重要特征<sup>[31]</sup>。本文将统计医生在医疗咨询平台上的历史参与情况，记为动态行为特征。在好大夫医疗平台中，医生可以开通个人问诊服务和团队问诊服务两个模块，由于精力和时间的限制，医生需要平衡在个人问诊和团队问诊两方面的投入。因此，动态特征包括医生个体层面动态行为特征（PD）和团队层面的动态交互特征（TD）。医生个体层面的动态行为特征是指医生以个人而非团队名义在在线医疗平台的活跃情况相关的结构化数据。由于预测目标为医生在团队问诊中的参与行为，团队层面交互特征包括结构化交互特征以及基于历史参与行为构造的动态行为特征。和静态时间段相比，为每个用户使用动态时间段构造动态特征，用户流失模型表现更优<sup>[34]</sup>。因此，本文根据实际数据情况分别基于固定时间段和动态时间段对医生的参与情况构造动态行为特征，包括参与行为的时间间隔和历史参与频数。团队问诊参与行为的时间间隔，以一个月作为参考期间，计算过去一个月（2020年3月）医生参与团队问诊行为的时间间隔并统计时间间隔的最大值、最小值、均值和标准差，对于过去一个月未参与团队问诊的医生，时间间隔标记为-1。关于历史参与频数，则基于动态时间段，分别以2天、3天、5天、7天、14天、21天的滑动窗口以1天作为步长捕捉医生过去一个月（2020年3月）参与团队问诊的频率。

以上动态行为特征构成动态行为特征集，记为FS2，特征说明如表2所示。

表2 动态行为特征集 FS2

动态特征分类	特征类型	特征说明
个体层面动态行为特征（PD）	数值型	热度、患者投票数（诊后评价数量）、疗效满意度、态度满意度、感谢信数量、心意礼物数量、总访问量、创作文章数、服务患者总数、微信诊后报到患者数、总诊后报到患者数、上次在线时间、本月在线情况、昨日诊后报到患者数、注册时长
团队层面动态交互特征（TD）	数值型	团队服务患者数、团队24小时回复率 医生参与团队问诊的频数统计（滑动窗口） 医生参与团队问诊的时间间隔统计情况，包括最大值、最小值、均值、标准差

## 4.3 交互文本特征集（FS3）

在线问诊发生时，交互文本是医生的重要输出，其实质内容受到医生团队和患者双方的共同关注。因此，本文基于医患沟通的交互文本，选择自然语言处理中词汇、句法、语义和语用四种语言风格维度作为特征构造的参考依据，构造交互文本特征集，并在后续的研究中验证交互文本特征对在线医生团队成员参与行为预测模型的有效性。其中，词汇特征（TL-L）聚焦于句子中单词的使用，尤其是词汇丰富程度<sup>[35]</sup>，这一特征被认为是语言学研究中常见的词汇特征之一；句法特征（TL-ST）侧重于语法和句

子中词语的恰当使用,如文本的长度<sup>[35,36]</sup>、词汇数量;语义特征(TL-SM)则关注词语出现的意义,如极性用语和健康词汇<sup>[37]</sup>;语用特征(TL-P)是指词语的意义和在适当语境中的词语选择,代表特征是语言的共享性。使用与社会群体相匹配的词语和语言,可以极大地提高沟通和社会接受的有效性<sup>[36]</sup>,此外,共同语言能够提升知识分享的意愿<sup>[38]</sup>,对于促进医生在团队问诊中发挥作用至关重要。语言共享的计算基于适用于健康语言环境的风格匹配测量<sup>[30,36]</sup>,首先计算每个医生全部文本情感历程词、感知历程词和生理历程词及其子类的个数并使用子类用词个数除以所在大类用词个数以计算医生  $j$  在子类  $k$  的倾向,记为  $P_{jk}$ ,然后计算其他医生的用词倾向记为  $\neg P_{jk}$ ,则用户  $j$  对于子类别  $k$  的语言风格匹配参考式(1),从而得到语用特征。

$$\text{LSM}_{jk} = 1 - \frac{(|P_{jk} - \neg P_{jk}|)}{(|P_{jk} + \neg P_{jk} + 0.0001|)} \quad (1)$$

词汇划分基于语言查询与词汇统计(linguistic inquiry and word count, LIWC)理论,使用中国科学院心理研究所研发的针对中文文本的分析软件——文心(TextMind)进行计算。LIWC是一种文本分析方法,用于词汇计数、词汇运用和语言风格的表征,可用于分析词汇的用法和词语运用背后的心理过程<sup>[39]</sup>,基于该工具针对中文研发的软件文心也在中文文本分析中被研究者使用<sup>[30]</sup>。本文关注LIWC中与健康相关的极性用语和健康词汇,包含情感历程词、感知历程词、生理历程词三个大类。为了验证用户在不同时间段的语言使用对团队参与行为预测的作用,除了基于全部文本构造特征,还使用动态时间段构造动态特征,针对词汇、句法、语义三类特征,分别计算每个医生过去12个月每个月的文本特征。对于第四类语用分析中的共享特征,则按照LIWC的类别划分进一步细化。

以上交互文本特征构成交互文本特征集,记为FS3,特征说明如表3所示。

表3 交互文本特征集FS3

交互文本特征分类	特征类型	特征说明
词汇(TL-L)	数值型	词汇丰富度
句法(TL-ST)	数值型	平均每条文本总词数 每句平均词数
语义(TL-SM)	数值型	积极词汇 消极词汇 感知历程词 生理历程词
语用(TL-P)	数值型	情感历程词共享,包括积极情绪词汇共享、消极情绪词汇共享、焦虑情绪词汇共享、 生气情绪词汇共享、悲伤情绪词汇共享 感知历程词共享,包括听觉词汇共享、触觉词汇共享、视觉词汇共享 生理历程词共享,包括身体词汇共享、性词汇共享、摄食词汇共享、健康词汇共享

#### 4.4 特征选择结果

特征过多会影响模型的效果和效率,Boruta特征选择算法是一种基于随机森林的全特征选择方法,该算法的核心思想是通过比较原始特征与随机生成的虚假特征(称为影子特征)的重要性来进行特征选择。Boruta算法的优点是它能有效识别对模型有重要贡献的特征,而无需预先设定特征的重要性阈值,在处理高维数据集和存在大量无关特征的数据集时表现良好<sup>[40]</sup>。鉴于Boruta的优势,

本文使用 Boruta 进行特征选择，最终筛选出对模型预测最有帮助的 76 个重要特征，包括 18 个静态属性特征，16 个动态行为特征和 42 个交互文本特征，FS1、FS2 和 FS3 在经过筛选后形成 FS1'、FS2' 和 FS3'。表 4 展示了筛选后的特征和团队成员是否参与的相关系数和显著性水平。表中文本特征后缀数字表示年月，如“积极词汇\_2001”表示医生于 2020 年 1 月在参与团队问诊时交互文本中积极词汇运用占比。筛选后的重要特征涵盖了本文 4.1 节至 4.3 节特征构造的各个维度，验证了特征构造视角的有效性。在筛选出的特征中，交互文本特征数量较多，包括词汇丰富度、词数、每句平均词数、积极情绪、消极情绪、感知历程词、生理历程词和健康词汇共享，涵盖了交互特征的词法、句法、语义、语用四个维度，说明交互文本特征的构造维度是合理的，且对于医生行为的预测十分重要。此外，同一交互文本特征在不同月份的使用情况也被筛选出来，以词汇丰富度为例，2019 年 4 月、7 月、9 月和 2020 年 1 月、2 月、3 月的特征均有助于团队成员参与行为的预测，验证了使用动态时间段构造动态特征的有效性。

表 4 重要特征和成员参与行为相关性

变量	相关系数	变量	相关系数	变量	相关系数	变量	相关系数
主任医师副教授 (LS)	0.007	普外科 (LS)	0.023	词数_1911 (TL-ST)	0.197***	积极词汇_1908 (TL-SM)	0.285***
北京协和医院 (LS)	0.021	眼科 (LS)	0.029	词数_1912 (TL-ST)	0.205***	积极词汇_2001 (TL-SM)	0.197***
耳鼻咽喉头颈外科 (LS)	-0.033	团队服务价格 (TS)	0.099***	词数_2001 (TL-ST)	0.339***	积极词汇_2002 (TL-SM)	0.205***
北京大学人民医院 (LS)	-0.025	注册时长 (PD)	0.180***	词数_2003 (TL-ST)	0.379***	积极词汇_2003 (TL-SM)	0.189***
郑州大学第一附属医院 (LS)	0.047**	骨科 (PS)	-0.071***	词数_全文本 (TL-ST)	-0.077**	生理历程词_1904 (TL-SM)	0.135***
上海市第一妇婴保健院 (PS)	0.191***	住院医师 (PS)	-0.059***	丰富度_1904 (TL-L)	0.071**	生理历程词_1908 (TL-SM)	0.216***
副主任医师副教授 (PS)	-0.014	肝胆外科 (PS)	-0.017	丰富度_1907 (TL-L)	0.140***	生理历程词_1909 (TL-SM)	0.182***
副主任医师讲师 (PS)	-0.026	团队 24 小时回复率 (TD)	0.215***	丰富度_1909 (TL-L)	0.188***	生理历程词_1911 (TL-SM)	0.253***
团队成员医院等级平均值 (TS)	0.044	团队服务患者数 (TD)	0.162***	丰富度_2001 (TL-L)	0.187***	生理历程词_1912 (TL-SM)	0.168***
团队成员城市等级最小值 (TS)	0.128***	热度 (PD)	0.413***	丰富度_2002 (TL-L)	0.228***	生理历程词_2003 (TL-SM)	0.368***
微信诊后报到患者数 (PD)	0.371***	感谢信数量 (PD)	0.359***	丰富度_2003 (TL-L)	0.249***	生理历程词_全文本 (TL-SM)	-0.174***
昨日诊后报到患者数 (PD)	0.411***	总访问量 (PD)	0.352***	丰富度_全文本 (TL-L)	-0.281***	感知历程词_1905 (TL-SM)	0.064*
上月末七天平均时间间隔 (TD)	0.324***	创作文章数 (PD)	0.247***	语言共享_触觉词 (TL-P)	-0.032	感知历程词_1909 (TL-SM)	0.128***
上月末七天最大时间间隔 (TD)	0.350***	患者投票数 (PD)	0.379***	语言共享_视觉词 (TL-P)	0.089***	感知历程词_2001 (TL-SM)	0.250***

续表

变量	相关系数	变量	相关系数	变量	相关系数	变量	相关系数
上月末七天时间间隔标准差 (TD)	0.426***	上次在线时间 (PD)	-0.361***	语言共享_身体词 (TL-P)	0.048	感知历程词_2003 (TL-SM)	0.287***
上月 1 天前两日参与频数 (TD)	0.113***	每句平均词数_1907 (TL-ST)	0.278***	语言共享_健康词 (TL-P)	0.035	感知历程词_全文本 (TL-SM)	-0.025
上月 7 天前两日参与频数 (TD)	0.120***	每句平均词数_1911 (TL-ST)	0.320***	语言共享_悲伤词 (TL-P)	-0.086***	语言共享_消极词汇 (TL-P)	-0.005
上月 16 天前两日参与频数 (TD)	0.228***	词数_1908 (TL-ST)	0.200***	消极词汇_1906 (TL-SM)	0.224***	消极词汇_1911 (TL-SM)	0.191***
中国医学科学院整形外科医院 (PS)	0.048**	词数_1910 (TL-ST)	0.173***	消极词汇_1907 (TL-SM)	0.241***	消极词汇_2002 (TL-SM)	0.232***

\*\*\*表示  $p < 0.01$ , \*\*表示  $p < 0.05$ , \*表示  $p < 0.1$ 

## 5 分类预测及集成学习策略

基于筛选后的特征,使用六种个体分类器分别建立预测模型并对比六种分类器的表现,基于预测效果较好的分类器,使用 SHAP 值对特征重要性进行解释,并提出两种集成策略进一步提升参与行为预测模型的分类能力。

### 5.1 预测模型

#### 5.1.1 分类器选择

为了对比不同类型模型的性能,充分发挥各类模型的优势,本文分别选择了树模型、神经网络模型和基于实例的非参数模型,具体为梯度提升决策树模型和随机森林、多层感知机、K 近邻算法。梯度提升决策树模型包括 XGBoost、LightGBM、CatBoost 三种,其中 XGBoost 因其强大的正则化处理能力表现出色<sup>[41]</sup>,LightGBM 具备更快的训练速度<sup>[42]</sup>,而 CatBoost 在处理分类特征上进行了创新<sup>[43]</sup>。模型及其类型见表 5。

表 5 分类器选择

模型	模型类型
梯度提升决策树模型	树模型
随机森林	树模型
多层感知机	神经网络模型
K 近邻算法	基于实例的非参数模型

#### 5.1.2 分类器评估指标

对在线医生团队成员参与团队问诊行为的预测模型属于二分类问题,1 代表参与,0 代表未参与。

准确预测医生的参与情况,有利于促进医生团队的动态运营,在本文的预测场景下,预测的精确率和召回率都很重要,本文使用精确率、召回率、F1 值对模型分类结果进行评估。

### 5.1.3 沙普利加和解释

以上提到的机器学习算法虽然预测效果好,但可解释性差。2017 年, Lundberg 和 Lee 提出了 SHAP 法<sup>[44]</sup>,能反映每个特征对预测的贡献,并展示特征对预测目标的影响。SHAP 值基于 Shapley 值,用于量化每个特征对模型的贡献,其核心思想是针对每个特征,计算特征在决策路径中的边际贡献,并计算所有路径中的平均边际贡献,得到特征的 SHAP 值。SHAP 值的计算公式<sup>[44]</sup>如式(2)所示:

$$\phi_i(f, x) = \sum_{z' \subseteq x'} \frac{|z'|!(M-|z'|-1)!}{M!} [f_x(z') - f_x(z' \setminus i)] \quad (2)$$

其中,  $x'$  表示输入的特征;  $M$  表示维度;  $f$  表示利用所传入的特征集,根据树的结构和叶子节点的取值等计算出样本的平均值;  $z' \in \{0,1\}^M$ , 表示在全部的  $M$  个特征中,该样本所在决策路径中包含的特征;  $f_x(z')$  表示该特征序列加入特征  $i$  后样本的平均值;  $f_x(z' \setminus i)$  表示在当前特征序列中未加入特征  $i$  时样本的平均值;  $\frac{|z'|!(M-|z'|-1)!}{M!}$  表示样本取值之差  $f_x(z') - f_x(z' \setminus i)$  的权重。

一个特征的 SHAP 值的绝对值越大,对于模型预测能力而言越重要。对于整个数据集的特征重要性,本文针对每个样本根据以上公式对每个特征计算 SHAP 值,取 SHAP 绝对值的均值可得到单个特征在整个数据集上的重要性。该方法可用于解释各种复杂的机器学习算法,包括树模型<sup>[45]</sup>、神经网络模型、深度学习模型及自然语言处理模型。本文采用 SHAP 值对模型中的特征进行分析,增强模型的可解释性。

### 5.1.4 集成学习策略

集成学习是指结合多个学习器以完成学习任务,降低过拟合<sup>[46]</sup>,提升模型的泛化能力。集成学习的原理为:首先构建一组个体学习器,然后通过集成策略将它们结合,集成相同类型的学习器为同质集成,集成不同类型的学习器为异质集成。对于分类任务,集成学习也叫多分类器系统。

研究表明,对单个分类器进行阈值调整可能会提升其表现<sup>[47]</sup>,投票法是指对多个个体分类器的分类器结果通过投票的方式决定最终输出结果,是最简单的集成学习方法,根据以上思想,提出集成策略 1:基于最佳决策阈值的投票集成策略。Wang 等<sup>[48]</sup>证明了基于权重的集成算法通过给集成分类器中的每一个个体分类器分配权重,来帮助集成分类器减少分类误差,借鉴该思想,提出集成策略 2:基于权重的集成策略。两种集成策略均集成了不同类型的学习器,因此属于异质集成策略。两种集成策略涉及各分类器输出的预测概率值  $p$  和概率阈值  $t$ ,对于每个样本,每个个体分类器均会输出将其预测为正例的概率值,记为  $p$ ,  $p_{ki}$  表示第  $k$  个分类器将第  $i$  个样本预测为 1 的概率,个体分类器在执行分类任务时,默认  $p > t(t=0.5)$  时判定为正例。具体策略介绍如下。

#### 1. 基于最佳决策阈值的投票集成策略

在集成策略 1 中,同时调整每个个体分类器的概率阈值  $t$ ,当  $p_{ki} > t_k$  时,该分类器输出值  $v_{ki}$  为 1,否则为 0,最后,四个分类器通过投票的方式集成,当票数大于 2 时,样本最终被判定为正例,反之为负例,算法流程如图 2 所示。

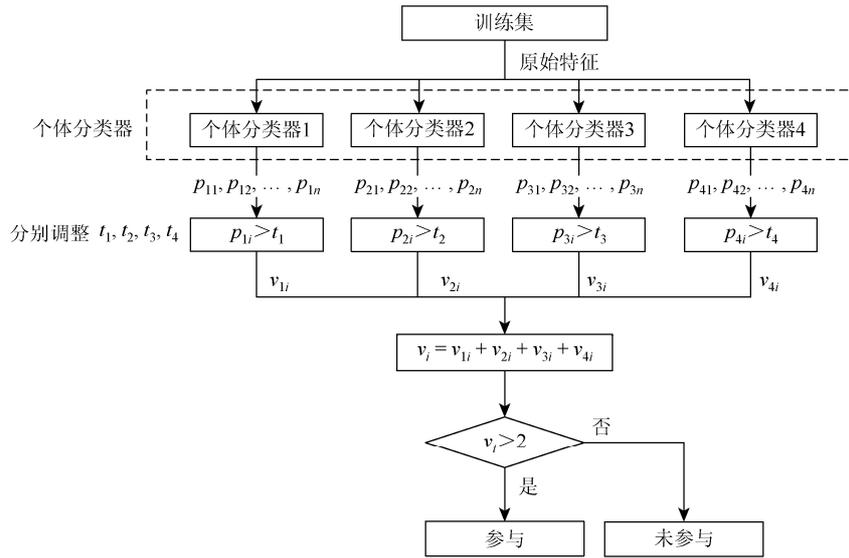


图 2 基于最佳决策阈值的投票集成策略（策略 1）

2. 基于权重的集成策略

在集成策略 2 中，为每个个体分类器输出的预测概率赋权，权重  $w_k$  作为一个参数，遍历该参数，各个分类器预测概率和权重的乘积之和为  $p_i$ ，最后，调整集成后的概率阈值参数  $t$ ，当  $p_i > t$  时，样本最终被判定为正例，反之为负例，算法流程如图 3 所示。

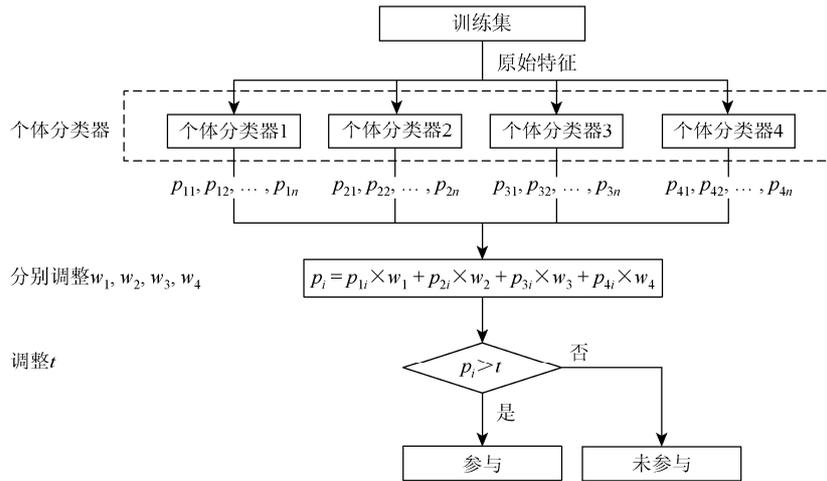


图 3 基于权重的集成策略（策略 2）

5.2 模型结果

首先，参考数据集中参与行为的比例，将数据集按照比例 7 : 3 划分为训练集和预测集，得到 1588 条训练样本和 681 条测试样本。为了验证交互文本特征在模型中的贡献以及集成学习相较单一分类器对预测结果的提升，分别构建三类模型：C1, C2, C3。其中，第一类模型 C1 包括特征筛选后的静态属性特征和动态行为特征，即 FS1'和 FS2'，第二类模型 C2 在模型 C1 的基础上添加了筛选后的交互文本特征，

即 FS3'，模型 C1 和模型 C2 均使用单个分类器进行模型的训练，模型 C3 基于模型 C2 添加了集成策略的应用。各类模型与特征集和分类器的对应关系如表 6 所示。

表 6 模型介绍

模型	C1	C2	C3
特征集	FS1' + FS2'	FS1' + FS2' + FS3'	FS1' + FS2' + FS3'
分类器	单个分类器	单个分类器	集成策略

### 5.2.1 模型 C1 的结果

表 7 展示了仅加入静态属性集和动态行为特征集的模型 C1 的结果。结果显示，静态属性特征和动态行为特征能够有效预测在线医生团队中成员的参与行为。根据各模型的精确率、召回率以及  $F1$  值可以发现，XGBoost、LightGBM、CatBoost、随机森林算法在本数据集上的预测能力明显优于 K 近邻算法和多层感知机，LightGBM 此时表现最佳。

表 7 C1 模型表现

模型类型	分类器	精确率	召回率	$F1$
C1	XGBoost	0.853	0.819	0.836
	LightGBM	0.863	0.825	0.844
	CatBoost	0.863	0.820	0.841
	随机森林	0.862	0.818	0.840
	K 近邻	0.786	0.737	0.761
	多层感知机	0.724	0.683	0.703

### 5.2.2 模型 C2 的结果

表 8 展示了在 C1 模型基础上进一步考虑交互文本特征集后的模型 C2 的表现。和模型 C1 类似，XGBoost、LightGBM、CatBoost、随机森林算法在本数据集的表现仍旧优于 K 近邻算法和多层感知机。对比表 7 和表 8 的结果，六种分类器的表现在加入文本特征后均有显著提升，验证了本文之前的猜想，团队问诊的交互文本特征有助于在线医生团队中的成员参与团队问诊行为的预测。

表 8 C2 模型表现

模型类型	分类器	精确率	召回率	$F1$
C2	XGBoost	0.877	0.843	0.859
	LightGBM	0.881	0.846	0.863
	CatBoost	0.880	0.841	0.860
	随机森林	0.871	0.831	0.851
	多层感知机	0.796	0.752	0.773
	K 近邻	0.744	0.695	0.719

### 5.2.3 SHAP 值解释结果

为了增强模型的可解释性,本文针对模型预测表现较好的梯度提升决策树输出每个样本每个特征的 SHAP 值的绝对值以查看特征的重要性。表 9 展示了最重要的前 15 个特征及其 SHAP 值的绝对值,可以发现静态属性特征(TS)、动态行为特征(TD、PD)以及交互文本特征中的语义(TL-SM)、句法(TL-ST)和词汇(TL-L)对于模型的预测都很重要。

表 9 最重要前 15 个特征的 SHAP 值

序号	特征名称	SHAP 值
1	上月末七天平均时间间隔 (TD)	0.827
2	上次在线时间 (PD)	0.513
3	昨日诊后报到患者数 (PD)	0.338
4	团队服务患者数 (TD)	0.258
5	生理历程词_2003 (TL-SM)	0.224
6	总访问量 (PD)	0.210
7	注册时长 (PD)	0.199
8	患者投票数 (PD)	0.198
9	词数_2003 (TL-ST)	0.196
10	团队服务价格 (TS)	0.185
11	创作文章数 (PD)	0.169
12	积极词汇_2003 (TL-SM)	0.168
13	丰富度_2003 (TL-L)	0.144
14	热度 (PD)	0.139
15	微信诊后报到患者数 (PD)	0.134

对于二分类问题,Python 的 SHAP 包提供了绘图功能展示每个样本每个特征的 SHAP 值<sup>[49]</sup>。图 4 展示了特征重要性排在前 15 的特征在每个样本预测中的 SHAP 值。图中横坐标表示 SHAP 值,颜色代表特征值的大小,深色表示特征值较大,浅色表示特征值较小。SHAP 值为正时,表示特征的贡献表现在将样本预测为 1,SHAP 值为负时,表示特征的贡献表现在将样本预测为 0。

从图 4 可以看出,在动态行为特征集中,上月末七天平均时间间隔更大时,医生更容易参与在线医生团队,该变量表现为一个负向指标的原因是,上月末七天医生没有参与团队问诊时,为了和已参与的医生进行区分,缺失值填充为-1,由于参与团队问诊的医生占比只有约 20%,因此-1 较多,受该值的影响,该特征为正值时表示医生在上个月最后七天有参与团队问诊的行为,因此可解释为上个月最后七天在团队问诊中活跃的医生在预测月份参与问诊的可能性更大,在团队问诊中保持活跃的医生可能具有更高的工作投入和积极性,因此更有可能参与问诊活动。此外,上次在线时间与距离截止计算时间较短的医生更容易发生团队问诊的参与行为,医生在短时间内频繁上线,可能表示他们对团队问诊的重视程度较高,愿意在平台上投入更多的时间与团队合作,并为患者提供咨询和治疗服务。昨日诊后报到患者

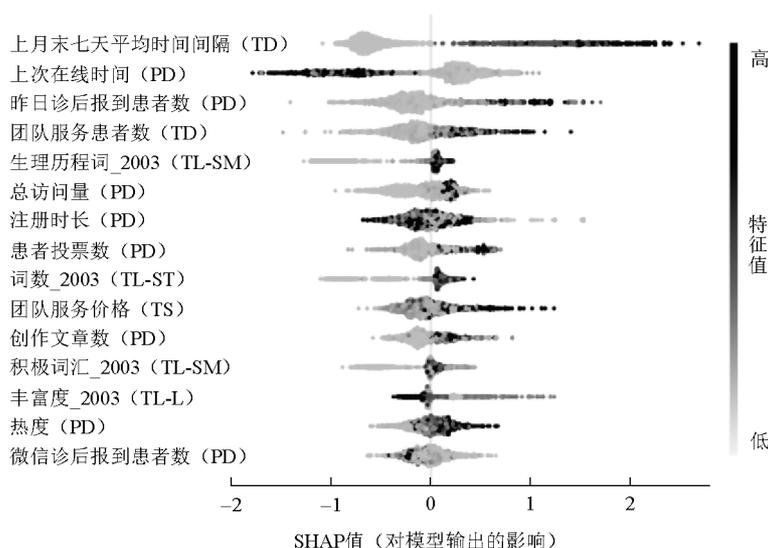


图4 SHAP 值

数、总访问量、患者投票数、热度、微信诊后报到患者数代表了医生的受关注程度，文章数反映了医生以个人而非团队形式在该平台的投入，团队服务患者数代表团队的决策资本，团队服务价格作为质量表征表示团队的问诊服务水平，这些动态行为特征取值较大，说明医生在在线问诊平台上具有较高的受关注程度和认可度。这可能会给医生提供更多的动力和动机参与到团队问诊中，以进一步提供高质量的服务和获得更多的专业认可。从图中来看，医生注册时长这一特征的高取值样本在 SHAP 值的正负两侧均有分布，说明该特征对模型预测存在显著影响（正向或负向）。一方面，医生在平台上注册时间较长可能表示医生对在线医疗平台的信任和认可程度较高，愿意在该平台上持续开展问诊服务，此种情况下，医生可能已经建立了一定的患者群体和专业声誉，因此更有动力和意愿参与团队问诊，进一步提供高质量的医疗服务；另一方面，尽管注册时间较长的医生已经加入医生团队，但他们可能仍保持原有的一对一问诊习惯，未实际参与团队问诊活动。

在静态属性特征集中，团队服务价格与医生在团队问诊中的参与行为呈现正向关系。较高的团队服务价格可能意味着团队提供的问诊服务具有较高的质量和专业水平。参与团队问诊可以带来更高的经济回报，医生可能会更有动力参与到团队问诊中，以提供与团队服务价格相匹配的高质量医疗服务。

此外，2020年3月（预测月份的前一个月）的交互文本特征中，更丰富的生理历程词、积极词汇、词数、健康词汇的使用都和医生在团队问诊中的参与行为呈现正向关系。医生在团队问诊中使用更丰富的生理历程词可能表示医生对患者病情的深入了解和分析能力，能够提供更准确和专业的医疗建议和诊断，可能会增加患者对医生的信任和满意度，促使医生更加积极地参与团队问诊。医生在团队问诊中使用积极词汇可能表明医生对患者积极乐观的态度和关怀，能够给予患者情绪上的支持和鼓励。这种积极的沟通方式有助于建立良好的医患关系，并激发患者对治疗的积极性和合作度，医生在团队问诊中得到积极反馈和患者的肯定可能会增强医生的参与行为。医生在团队问诊中使用更多的词数可能表示医生对患者问题的细致关注和全面分析能力。医生可能会更加详细地回答患者的问题，提供更全面的医疗建议和解决方案。医生在团队问诊中使用更多的健康词汇可能表示医生会给予患者关于预防、治疗和康复的相关建议，增强患者对医生的信任和依赖。医生在团队问诊中得到患者的认可和信任可能会增加医生参与团队问诊的动力。

### 5.2.4 集成学习结果

由模型 C1 和模型 C2 中的个体分类器的评估结果可知, 对于本数据集, 多层感知机和 K 近邻算法对于本文数据集的分类能力明显弱于 XGBoost、LightGBM、CatBoost 和随机森林, 因此后续的集成学习基于 XGBoost、LightGBM、CatBoost、随机森林四个分类器的输出结果。

表 10 展示了两种集成策略的最佳表现及对应参数的取值, 可以发现: ①本文提出的两种集成策略的  $F1$  值均高于前面单个个体分类器的预测表现 (表 7), 说明本文的集成策略可以提高分类结果。②基于最佳决策阈值的投票集成策略 (策略 1) 表现优于基于权重的集成策略 (策略 2)。在策略 1 的集成过程中, LightGBM 和随机森林的最佳概率阈值均发生了变化, 分别为 0.43 和 0.48; 在策略 2 的集成过程中, 作为和 XGBoost、LightGBM 相似的分类器, CatBoost 的权重最小 (0.09)。最终, 基于最优策略 (策略 1) 在测试集上进行预测, 得到 184 个正例。

表 10 基于 C3 模型的两​​种集成策略表现对比

模型类型	集成策略					
	基于最佳决策阈值的投票集成策略 (策略 1)			基于权重的集成策略 (策略 2)		
C3	精确率	召回率	$F1$	精确率	召回率	$F1$
	0.890	0.852	0.871	0.886	0.844	0.864
个体分类器	概率阈值 $t_k$			$t = 0.56$ , 权重 $w_k$		
XGBoost	0.50			0.39		
LightGBM	0.43			0.30		
CatBoost	0.50			0.09		
随机森林	0.48			0.22		

### 5.3 结果讨论

基于医生层面的静态属性特征集和动态行为特征集, 对比梯度提升决策树算法 (XGBoost、LightGBM 和 CatBoost)、随机森林、K 近邻和多层感知机共六种分类器结果发现, 医生的静态属性特征和动态行为特征可以有效预测在线医生团队中成员的参与行为, 且 LightGBM 模型的表现优于其他分类器。

在医生的静态属性特征集和动态行为特征集的基础上, 加入医生的交互文本特征集后, 六种分类器模型的精确率、召回率和  $F1$  值均有 0.02 左右的提高, 验证了交互文本特征对预测模型的提升效果。说明医生的交互文本特征有助于预测在线医生团队中的成员参与团队问诊行为, 且 LightGBM 模型的表现优于其他分类器。

为了进一步提高模型的可解释性, 本文引入了 SHAP 法对特征重要性进行分析, 验证了交互文本特征构造的有效性并展示了各个指标的取值对模型预测效果的影响。根据 SHAP 结果发现, 在影响预测在线医生团队成员的参与行为的最重要的前 15 个特征中: ①在动态行为特征方面, 上个月最后七天在团队问诊中活跃和上次在线时间与距离截止计算时间较短的医生更有可能在参与问诊活动。昨日诊后报到患者数、总访问量、患者投票数、热度、微信诊后报到患者数较高的医生具有较高的受关注程度和认可度, 参与到团队问诊中的动力也较大。此外, 在平台上注册时间较长的医生可能对平台的信任较高, 更愿意在平台上持续开展服务, 参与团队问诊的积极性也较高。②在静态属性特征中, 团队服务价格与医

生参与团队问诊行为的相关性更高。③在交互文本特征中,生理历程词、积极词汇使用频率较高的医生,可以体现医生的专业性,提高患者对医生的信任,提高医生参与团队问诊的动力。

此外,对于分类表现较好的 XGBoost、LightGBM、CatBoost 和随机森林四种分类器,基于最佳决策阈值的投票集成策略进一步提升了模型的预测性能。与单个分类器相比,两种集成策略均获得了提升,这说明通过集成多个分类器的预测结果,可以获得比单个分类器更可靠和准确的预测。与基于权重的集成策略相比,基于最佳决策阈值的投票集成策略更适用本文的研究问题。

在平台层面,在线医疗咨询平台作为医疗信息传播的重要渠道,需要医生用户的积极参与,分享他们的专业知识和经验。如果团队成员不能积极参与到团队问诊中,那么团队服务模式的价值和潜力将无法实现。根据本文提出的模型,平台可以预测出参与度较低的医生,并为他们提供针对性的激励措施,如发送提醒、提供培训和支持,以提升其参与度。此外,平台还可以依据预测结果,优化医生的激励机制,确保医生在团队问诊中的参与得到及时的认可和反馈。例如,热度是预测参与行为的重要特征之一,平台可适当提升团队问诊参与频率在医生热度中的权重,激发医生的参与动力,从而有效鼓励医生参与团队问诊,促进团队整体参与度和问诊效率的提升。预测结果为参与度高的医生,是平台需要深度维护的高价值用户,针对这部分忠实用户,平台应制定合理的维护措施,如提供额外激励以实现长期、持续的参与,充分发挥此类用户在平台中的重要价值。

在团队层面,首先,团队服务价格是团队层面预测参与行为的重要特征,在保证问诊质量的前提下适当提高团队服务价格这一正向激励,有利于提高团队成员的积极性。其次,团队领导者应关注团队成员近期在平台上的活跃情况,针对参与程度低的成员,了解其参与动机并采取合适的激励政策,如在团队内部设置明确的参与目标、制定合理公平的问诊收益分成策略,增强团队认同感,从而激励团队成员积极参与问诊,促进团队整体服务水平的不断提升,充分发挥在线医生团队的社会价值。

## 6 结论

### 6.1 研究结论

在互联网时代和后疫情时代的背景下,在线医生团队能够高效整合医疗资源,跨越时间和地域的边界,通过线上渠道更加快捷、高效地为患者提供高质量医疗咨询服务。已有研究探索了在线医生团队的形成机制<sup>[6]</sup>,但为了促进在线医生团队的持续发展,本文深入分析了团队成员的参与行为。基于在线医生团队的属性数据和医患交互数据,本文进一步考察了交互文本特征在行为预测中的重要作用。为识别预测团队成员参与行为的最佳模型,本文应用多种机器学习模型构建了分类预测模型,对比了不同机器学习模型在该数据集上的表现,并进一步提出了两种集成策略,基于最佳决策阈值的投票集成策略和基于权重的集成策略,来提高模型的预测能力,得到以下主要结论。

第一,在医患交互场景下,添加交互文本特征比仅仅使用静态属性特征和动态行为特征,显著提升了各分类器的表现。近年来,越来越多的行为预测研究从实际场景出发构造特征,例如,由于群聚效应对新技术采纳起到促进作用,在预测移动支付系统商户采纳行为时构造群聚效应特征<sup>[50]</sup>;而用户业务特征由于与用户操作行为的关联性,使其在企业信息系统用户异常行为预测模型中起到了关键作用<sup>[24]</sup>;本文则验证了在线医生团队与患者交互的场景下,基于语言风格的交互文本特征在预测团队医生参与行为中有效提升了模型表现。第二,对于团队医生行为预测,XGBoost、LightGBM、CatBoost 和随机森林算法的表现优于 K 近邻和多层感知机,特别是 LightGBM 表现最优。同为在线健康场景下的行为预测,

XGBoost 和随机森林分别在健康应用程序使用行为预测和电子健康平台用户退出行为预测中取得了较好的预测效果<sup>[28, 29]</sup>, 而对于医生团队问诊参与行为预测而言, LightGBM 是最优选择。第三, 三类特征对于模型的预测都很重要, 在动态行为特征中, 区别于仅仅构建时间间隔特征<sup>[24]</sup>, 基于动态时间窗口构造的预测时间附近医生在平台和团队的历史活跃情况, 更能细致地捕捉医生的行为变化, 是提升模型性能的关键发现。第四, 对于分类表现较好的 XGBoost、LightGBM、CatBoost 和随机森林四种分类器, 基于最佳决策阈值的投票集成策略和基于权重的集成策略均能够提升模型的预测能力, 基于最佳决策阈值的投票集成策略表现最好,  $F1$  值达到 0.871, 能够有效预测团队成员的参与行为, 为平台和团队领导者实现团队的动态管理提供了前期准备的依据和方法。

## 6.2 研究贡献

### 6.2.1 理论意义

第一, 过往研究主要集中于团队协作的内部机制, 较少关注团队成员的参与行为, 本文首次关注团队成员参与行为这一新场景。在特征构造方面, 本文引入了语言风格视角, 将基于语言风格构造的交互文本特征作为医生行为画像的重要部分, 显著提升了团队问诊参与行为预测模型的表现, 验证了语言风格在行为建模中的关键作用。这一对语言风格框架的创新应用不仅为未来行为预测的特征构建提供了新的思路和方法, 也丰富了行为预测相关研究。

第二, 提出基于最佳决策阈值的投票集成策略和基于权重的集成策略, 并验证了两种集成策略在医生团队参与行为预测中的有效性和优势。这为模型集成方法提供了新的技术路径, 也为后续优化分类模型集成策略提供了有益的参考。

### 6.2.2 实际意义

第一, 对于在线医生团队而言, 本文通过对在线医生团队中成员的参与行为进行预测并对参与行为特征体系进行解释, 可以帮助医疗团队更好地了解团队成员的参与程度和行为特征, 有助于团队管理者 and 决策者识别和优化医生团队中的资源分配, 进一步提高医疗团队的工作效率。

第二, 对于平台的医疗资源配置而言, 高参与度的医疗团队有利于及时、高效地解决患者的问题, 患者免于复杂的看病流程和地理位置的限制。对在线医生团队进行研究并提出管理建议, 有利于进一步促进医疗资源的合理分配, 充分发挥医疗资源的社会价值。

第三, 通过构建预测模型和提出集成策略, 本文为其他平台远程团队的协作提供了有效的技术支持, 以便他们能够预测成员的参与情况并进行相应的资源规划, 有助于促进远程医疗的实施和推广。

## 6.3 研究展望

不同平台的功能设计与用户行为模式的差异可能对模型的预测结果产生影响。未来, 研究将扩展至多个在线医疗咨询平台, 整合多平台数据, 以进一步提升研究结果的普适性。此外, 在线医生团队成员参与行为的预测模型还可以进一步完善。首先, 受限于机器学习方法的缺点, 本文只能尽可能提高模型的预测能力, 从预测的角度发现重要特征, 无法解释单个特征对于预测模型起作用的内在机理。其次, 可以考虑构造更加丰富的特征, 如团队内其他成员的参与积极性。最后, 在算法的应用方面, 未来可尝试不同类型的集成策略, 在方法上进一步创新, 提升分类模型的表现。

## 参考文献

- [1] Wu H, Deng Z H, Wang B, et al. How online health community participation affects physicians' performance in hospitals: empirical evidence from China[J]. *Information & Management*, 2021, 58(6): 103443.
- [2] 刘璇, 潘明天, 陈梅梅, 等. 医院间合作网络对医院绩效的影响研究: 基于在线健康咨询平台的实证分析[J]. *信息系统学报*, 2019, (2): 86-102.
- [3] Kelly S L, Jackson J E, Hickey B E, et al. Multidisciplinary clinic care improves adherence to best practice in head and neck cancer[J]. *American Journal of Otolaryngology*, 2013, 34(1): 57-60.
- [4] 刘璇, 陈晋, 陈梅梅. 知识多样性及任务依赖性对团队绩效的影响[J]. *系统管理学报*, 2021, 30(5): 961-970.
- [5] 司广森, 刘汕, 吴依珂. 在线健康平台医生团队多样性对服务绩效的影响研究[J]. *管理学报*, 2023, 20(3): 422-431.
- [6] 刘璇, 迟晓彤, 范静. 基于自动逻辑行动者属性模型的在线医生团队社会影响机理研究[J]. *管理学报*, 2021, 18(12): 1830-1839.
- [7] Meri n A, van de Ven J, Mol B W, et al. Multidisciplinary team training in a simulation setting for acute obstetric emergencies: a systematic review[J]. *Obstetrics and Gynecology*, 2010, 115(5): 1021-1031.
- [8] Steitz B D, Unertl K M, Levy M A. Characterizing communication patterns among members of the clinical care team to deliver breast cancer treatment[J]. *Journal of the American Medical Informatics Association*, 2020, 27(2): 236-243.
- [9] Li J, Bao X Y, Liu X, et al. The impact of joining a team on the initial trust in online physicians[J]. *Healthcare*, 2020, 8(1): 33.
- [10] Bell S T, Villado A J, Lukasik M A, et al. Getting specific about demographic diversity variable and team performance relationships: a meta-analysis[J]. *Journal of Management*, 2011, 37(3): 709-743.
- [11] 易思源, 王辉, 龚其国, 等. 团队经验多样性与团队绩效: 来自于制造业的证据[J]. *管理评论*, 2022, 34(7): 236-245.
- [12] Paul R, Drake J R, Liang H G. Global virtual team performance: the effect of coordination effectiveness, trust, and team cohesion[J]. *IEEE Transactions on Professional Communication*, 2016, 59(3): 186-202.
- [13] 席西民, 张华, 马骏. 成员间互动对团队绩效影响研究: 基于和谐管理理论的视角[J]. *运筹与管理*, 2008, 17(6): 134-139.
- [14] Amir Z, Scully J, Borrill C. The professional role of breast cancer nurses in multi-disciplinary breast cancer care teams[J]. *European Journal of Oncology Nursing*, 2004, 8(4): 306-314.
- [15] K nzle B, Kolbe M, Grote G. Ensuring patient safety through effective leadership behaviour: a literature review[J]. *Safety Science*, 2010, 48(1): 1-17.
- [16]  ulibrk J, Delic M, Mitrović S, et al. Job satisfaction, organizational commitment and job involvement: the mediating role of job involvement[J]. *Frontiers in Psychology*, 2018, 9: 132.
- [17] Ebeh R E, Njoku E C, Ikpeazu O C, et al. Organizational commitment and job involvement among casual workers: the role of organisational justice[J]. *Global Journal of Human Resource Management*, 2017, 5(4): 17-32.
- [18] R zewski P, Jankowski J, Br dka P, et al. Knowledge workers' collaborative learning behavior modeling in an organizational social network[J]. *Computers in Human Behavior*, 2015, 51: 1248-1260.
- [19] Cao W L, Xu L, Liang L, et al. The impact of team task and job engagement on the transfer of tacit knowledge in e-business virtual teams[J]. *Information Technology and Management*, 2012, 13(4): 333-340.
- [20] Huang W, Yuan C, Li M. Person-job fit and innovation behavior: roles of job involvement and career commitment[J]. *Frontiers in Psychology*, 2019, 10: 1134.
- [21] Berraies S, Chouiref A. Exploring the effect of team climate on knowledge management in teams through team work engagement: evidence from knowledge-intensive firms[J]. *Journal of Knowledge Management*, 2023, 27(3): 842-869.
- [22] Ding X, Li Q, Zhang H B, et al. Linking transformational leadership and work outcomes in temporary organizations: a social identity approach[J]. *International Journal of Project Management*, 2017, 35(4): 543-556.
- [23] Liao H, Liu D, Loi R. Looking at both sides of the social exchange coin: a social cognitive perspective on the joint effects

- of relationship quality and differentiation on creativity[J]. *Academy of Management Journal*, 2010, 53(5): 1090-1109.
- [24] 尹隽, 彭艳红, 陆怡, 等. 基于深度神经网络的企业信息系统用户异常行为预测[J]. *管理科学*, 2020, 33(1): 30-45.
- [25] Jaspersen J, Carter P E, Zmud R W. A comprehensive conceptualization of post-adoptive behaviors associated with information technology enabled work systems[J]. *MIS Quarterly*, 2005, 29(3): 525-557.
- [26] Shaban W M, Rabie A H, Saleh A I, et al. A new COVID-19 patients detection strategy(CPDS)based on hybrid feature selection and enhanced KNN classifier[J]. *Knowledge-Based Systems*, 2020, 205: 106270.
- [27] Mišić V V. Optimization of tree ensembles[J]. *Operations Research*, 2020, 68(5): 1605-1624.
- [28] Cho J, Kim S, Jeong G, et al. Investigation of influential factors of predicting individuals' use and non-use of fitness and diet apps on smartphones: application of the machine learning algorithm(XGBoost)[J]. *American Journal of Health Behavior*, 2021, 45(1): 111-124.
- [29] Pedersen D H, Mansourvar M, Sortsø C, et al. Predicting dropouts from an electronic health platform for lifestyle interventions: analysis of methods and predictors[J]. *Journal of Medical Internet Research*, 2019, 21(9): e13617.
- [30] Jiang S, Liu X, Chi X T. Effect of writing style on social support in online health communities: a theoretical linguistic analysis framework[J]. *Information & Management*, 2022, 59(6): 103683.
- [31] Bellotti T, Crook J. Forecasting and stress testing credit card default using dynamic models[J]. *International Journal of Forecasting*, 2013, 29(4): 563-574.
- [32] Deng Q, Hine M J, Ji S B, et al. Understanding consumer engagement with brand posts on social media: the effects of post linguistic styles[J]. *Electronic Commerce Research and Applications*, 2021, 48: 101068.
- [33] Wu H, Deng Z H. Knowledge collaboration among physicians in online health communities: a transactive memory perspective[J]. *International Journal of Information Management*, 2019, 49: 13-33.
- [34] Prasad U D, Madhavi S. Prediction of churn behavior of bank customers using data mining tools[J]. *Indian Journal of Marketing*, 2012, 42: 25-30.
- [35] Johnson S L, Safadi H, Faraj S. The emergence of online community leadership[J]. *Information Systems Research*, 2015, 26(1): 165-187.
- [36] Chen L T, Baird A, Straub D. A linguistic signaling model of social support exchange in online health communities[J]. *Decision Support Systems*, 2020, 130: 113233.
- [37] Ouyang P, Wang J J, Chang A C J. Patients need emotional support: managing physician disclosure information to attract more patients[J]. *International Journal of Medical Informatics*, 2022, 158(2): 104674.
- [38] Chiu C M, Hsu M H, Wang E T G. Understanding knowledge sharing in virtual communities: an integration of social capital and social cognitive theories[J]. *Decision Support Systems*, 2006, 42(3): 1872-1888.
- [39] Pennebaker J W, Boyd R L, Jordan K, et al. The development and psychometric properties of LIWC2015[R]. Austin: University of TexasAustin, 2015.
- [40] Kursu M B, Rudnicki W R. Feature selection with the Boruta package[J]. *Journal of Statistical Software*, 2010, 36(11): 1-13.
- [41] Chen T Q, Guestrin C. XGBoost: A scalable tree boosting system[C]//Krishnapuram B, Shah M. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York: Association for Computing Machinery, 2016: 785-794.
- [42] Ke G L, Meng Q, Finley T, et al. LightGBM: a highly efficient gradient boosting decision tree[C]//von Luxburg U, Guyon I. *Proceedings of the 31st International Conference on Neural Information Processing Systems*. New York: Curran Associates Inc. , 2017: 3149-3157.
- [43] Prokhorenkova L, Gusev G, Vorobev A, et al. CatBoost: unbiased boosting with categorical features[J]. *Advances in Neural Information Processing Systems*, 2018, 31: 6638-6648.
- [44] Lundberg S M, Lee S I. A unified approach to interpreting model predictions[C]//von Luxburg U, Guyon I. *Proceedings of the 31st International Conference on Neural Information Processing Systems*. New York: Curran Associates Inc. , 2017: 4768-4777.
- [45] Lundberg S M, Erion G, Chen H, et al. From local explanations to global understanding with explainable AI for trees[J].

- Nature Machine Intelligence, 2020, 2(1): 56-67.
- [46] Grushka-Cockayne Y, Jose V R R, Lichtendahl K C, Jr. Ensembles of overfit and overconfident forecasts[J]. Management Science, 2017, 63(4): 1110-1130.
- [47] Christenson R H, Phillips D. Sensitive and high sensitivity next generation cardiac troponin assays: more than just a name[J]. Pathology, 2011, 43(3): 213-219.
- [48] Wang H X, Fan W, Yu P S, et al. Mining concept-drifting data streams using ensemble classifiers[C]//Getoor L, Senator T. Proceedings of the Ninth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: Association for Computing Machinery, 2003: 226-235.
- [49] Lundberg S M, Nair B, Vavilala M S, et al. Explainable machine-learning predictions for the prevention of hypoxaemia during surgery[J]. Nature Biomedical Engineering, 2018, 2(10): 749-760.
- [50] 李莹莹, 李英. 基于分类算法的移动支付系统商户采纳行为预测模型[J]. 工业工程与管理, 2021, 26(5): 115-122.

## Research on the Prediction of Physicians' Participation Behavior in Team Consultation based on Integration Strategies

CHI Xiaotong, LIU Xuan, CHENG Yan, FENG Chengcheng

(School of Business, East China University of Science and Technology, Shanghai 200237, China)

**Abstract** Online physician teams are premium providers of telemedicine services. This study focuses on the “Haodf.com” platform, aiming to develop a classification model to predict team members' participation in online team consultations. The model incorporates three feature sets: static attributes, dynamic behaviors, and text features of team consultation. We compared the performance of gradient boosting decision trees, random forests, k-nearest neighbors, and multilayer perceptrons, using SHAP (Shapley additive exPlanations) to interpret feature importance. To enhance prediction performance, we proposed a voting ensemble strategy based on optimal thresholds and a weight-based ensemble strategy. Results indicate that text features of team consultations help enhance the model's performance. Ensemble strategies outperform individual classifiers, with the voting ensemble strategy based on the optimal thresholds showing the best performance. The findings provide insights for managing online medical teams and optimizing resource allocation.

**Key words** Online physician teams, Feature engineering, Behavior prediction, Integration strategies

### 作者简介

迟晓彤(1996—),女,华东理工大学商学院2024级博士研究生,研究方向为电子健康。E-mail: 15216689507@163.com。

刘璇(1982—),女,华东理工大学商学院教授、博士生导师,研究方向为电子健康。E-mail: xuanliu@ecust.edu.cn。

程岩(1967—),男,华东理工大学商学院教授、博士生导师,研究方向为数据科学。E-mail: yancheng@ecust.edu.cn。

冯程程(1999—),女,华东理工大学2021级硕士生,研究方向为电子健康。E-mail: 835138980@qq.com。