

基于用户生成内容与贝叶斯偏好分解的排序模型及应用

刘凡¹, 廖虎昌^{2†}

(1. 重庆交通大学 经济与管理学院, 重庆 400074; 2. 四川大学 商学院, 成都 610064)

摘要: 挖掘用户生成内容中的有效信息并为用户提供个性化产品排序是数智时代电商运营管理的新方向. 现有研究在分析文本评论情感时存在偏差进而影响排序效果; 此外, 现有推荐模型未考虑用户偏好不确定性对排序结果的影响. 为弥补上述不足, 提出一种用户生成内容环境下结合深度学习与贝叶斯偏好分解的排序模型. 首先, 为减少未标注评论的情感分类偏差, 提出基于预训练大语言模型的情感分类方法, 利用 BERTopic 主题模型挖掘用户关注的产品准则与关键词, 将标注数据用于 LoRA 微调 Chinese-RoBERTa 情感分类预训练模型. 其次, 利用蒙特卡洛模拟将准则偏好转换为贝叶斯先验信息, 构建不同类型的似然函数建模确定和不确定的产品偏好信息, 并结合贝叶斯准则与偏好分解方法计算产品排序的分布概率, 进而为用户进行排序推荐. 最后, 通过京东平台的医疗手环排序案例验证模型的有效性.

关键词: 偏好学习; 个性化产品排序; 用户生成内容; 情感分类; 贝叶斯准则; 偏好分解

中图分类号: C934 文献标志码: A

DOI: 10.13195/j.kzyjc.2025.1267

引用格式: 刘凡, 廖虎昌. 基于用户生成内容与贝叶斯偏好分解的排序模型及应用 [J]. 控制与决策.

A product ranking model based on user-generated content and Bayesian preference disaggregation and its applications

LIU Fan¹, LIAO Hu-chang^{2†}

(1. School of Economics and Management, Chongqing Jiaotong University, Chongqing 400074, China;
2. Business School, Sichuan University, Chengdu 610064, China)

Abstract: Extracting valuable information from online reviews and providing users with personalized product ranking is a new direction for e-commerce operations in the digital and intelligent era. Existing research resulted in biases in sentiment analysis of textual reviews, which may affect the accuracy of ranking results. Additionally, current recommendation models rarely considered the impact of user preference uncertainty on ranking outcomes. To fill these gaps, this study proposes a ranking model that combines deep learning with Bayesian preference disaggregation methods. First, to reduce sentiment classification bias for unlabeled reviews, a sentiment classification method based on a pre-trained large language model is proposed. Specifically, the BERTopic model is employed to extract product evaluation criteria and keywords that users are interested in from online reviews. The LoRA framework is utilized to fine tune the Chinese-RoBERTa sentiment classification pre-trained model based on labeled data. Monte Carlo simulation is used to convert criteria preferences into Bayesian prior information, constructing different types of likelihood functions to model both certain and uncertain product preference information. By combining the Bayesian rule and preference disaggregation method, the probability distribution for product ranking can be calculated, ultimately providing personalized recommendations to users. A case study of medical smartwatches recommendations on JD.com is conducted to verify the effectiveness of the proposed model.

Keywords: preference learning; personalized product ranking; user-generated content; sentiment classification; Bayesian rule; preference disaggregation

0 引言

相比传统的信息收集方式 (如问卷调查), 用户

生成内容易于获取且数据量更大, 能够真实反映消费者的需求与偏好, 弥补用户和商家之间的信息差

收稿日期: 2025-12-08; 录用日期: 2026-03-06.

基金项目: 国家自然科学基金项目 (72371173, 72171158); 四川省科技计划项目 (2025NSFJQ0072); 重庆市重点实验室绿色物流智能技术开放基金项目 (KLGLIT2025ZD001).

责任编辑: 黄敏.

†通信作者. E-mail: liaohuchang@163.com.

距, 并为其他消费者提供决策依据^[1]. 通过自然语言处理方法能从用户生成内容 (包括在线评论和评级) 中挖掘产品特征和用户偏好, 进而实现基于用户生成内容的产品排序推荐. 然而, 用户生成内容非结构化程度高, 信息质量良莠不齐^[2]. 此外, 不同消费者对产品属性 (如价格、功能) 或品牌的偏好各不相同, 单一的排序策略无法反映用户的个性化偏好. 同时, 受认知的局限, 消费者存在不准确或不确定的偏好, 如消费者认为产品 A 有 50% 的可能优于产品 B. 从用户生成内容中挖掘用户不确定偏好并开发个性化排序模型是数智时代电商运营管理的热门话题.

文本评论信息挖掘的研究主要从主题模型与情感分析两方面展开. 主题模型通过机器学习方法挖掘文本中用户关注的产品评价准则和关键词, 利用聚类方法将同一准则的关键词聚合在同一类别中^[3]. 现有研究通过潜在狄利克雷分布^[4]及其变体^[5]、词频-逆文本频率指数^[6]、结合聚类算法的 Word2Vec 算法^[7]等方法进行主题聚类. 然而, 以上方法无法捕捉词语和句子的深层语义以及上下文关系, 导致聚类结果忽略低频词和多义词. 情感分析通过自然语言处理方法对文本评论中用户表达的情感极性和强度进行分析, 量化用户对于产品各属性与整体的满意度^[3]. 现有研究通过开源情感分析工具, 如 Stanford NLP^[4]和 TextBlob^[8]、基于情感词典的方法^[9]、基于深度学习的情感分析方法^[10]从不同粒度 (词语或句子级别) 进行文本情感分析. 然而, 开源情感分析工具在分析训练语料之外的语料库上分类准确率较低; 基于情感词典的方法需要构建复杂的情感分析规则与语料库, 对于不规则的口语化文本分析偏差较大; 基于深度学习的情感分析方法专注于情感极性的分类, 无法区分相同情感极性但不同情感强度的评论. 因此, 有必要利用能捕捉词语和句子的深层语义以及上下文关系的主题模型挖掘主题关键词, 基于主题模型的计算结果提出能区分评论情感强度且减少情感分析结果偏差的方法, 为用户的个性化偏好挖掘和产品排序推荐提供数据基础.

基于用户生成内容的产品排序模型主要基于多准则决策方法与机器学习算法. 多准则决策方法如 TODIM 方法^[11]和 MULTIMOORA 方法^[12]被用来聚合从文本评论中挖掘的产品在多个准则下的评价信息进而获得产品排序. 基于机器学习的产品排序算法有考虑用户评论情感倾向相似度的协同过滤算法^[13]、融合文本评论情绪和评分矩阵的深度学习模型^[14]以及使用层级注意力网络学习产品及评论的最优特征表示的方法^[15]. TODIM 和 MULTIMOORA 方法要求用户给出反映其偏好的模型参数; 基于协

同过滤算法和深度学习的模型需要大量历史决策数据才能推荐符合用户偏好的产品. 上述模型尚无法解决历史决策数据较少且用户无法给出精确偏好参数时的产品推荐问题.

偏好分解方法能根据有限的历史决策数据分解出兼容用户偏好的值函数, 进而计算准则权重信息, 再结合准则评价聚合得到产品综合表现值用于产品排序^[16]. Wu 等^[16]利用概率语言术语集表征不确定的成对比较偏好信息, 构造了基于概率语言术语集的偏好分解模型计算兼容用户偏好的值函数用于产品排序, 但该模型需要复杂的后验分析过程处理不一致偏好信息. 学者^[17-18]结合贝叶斯准则与偏好分解方法生成一组兼容用户不一致偏好信息的值函数, 通过计算产品排名的概率分布来标注不一致偏好信息下的排序结果. 现有基于贝叶斯偏好分解的排序模型缺少对不同产品类型偏好信息^[17-18]和准则偏好信息^[18]的考虑, 这使得推荐的产品存在不符合用户偏好的情形. 因此, 有必要开发考虑不确定偏好信息的贝叶斯偏好分解模型应用到解决基于用户生成内容的产品推荐问题中.

为解决以上研究挑战, 提出结合深度学习方法与贝叶斯偏好分解的产品排序推荐模型. 首先, 基于大语言模型在语义理解与泛化学习上的优势, 提出基于预训练模型的情感分析方法来减少情感分析的偏差. 该方法利用 BERTopic^[19]主题模型结合预训练的词向量模型与聚类算法进行文本评论主题挖掘并聚类主题的关键词, 其能有效处理上下文语义关系, 准确聚类多义词和低频词. 采用 Low-Rank Adaptation (LoRA)^[20]框架在标注数据上微调 Chinese-RoBERTa^[21]预训练模型并对未标注评论进行情感分析. 接着, 提出考虑用户不确定偏好信息的贝叶斯偏好分解模型进行产品排序推荐. 该模型利用蒙特卡洛模拟将准则偏好信息转换为贝叶斯偏好模型的先验信息, 构建似然函数建模确定与不确定的产品偏好信息, 结合贝叶斯准则和偏好分解方法计算出一组兼容用户确定与不确定偏好的加性值函数, 为用户提供产品的排序分布信息. 最后, 利用 JD.com 的同类型医疗手环的用户生成内容数据, 验证所提情感分析方法在减少情感分析偏差以及产品排序推荐模型在考虑用户不确定偏好信息和进行个性化排序推荐的有效性. 本研究为数智时代下个性化产品排序推荐和服务质量管理提供了新方法.

1 基于用户生成内容与贝叶斯偏好分解的产品排序推荐模型

1.1 问题定义

在基于用户生成内容进行产品排序推荐时, 需

要从多个维度(准则)评估同类产品的表现,并通过聚合各准则的评价值和权重得出产品的综合表现值,根据综合表现值为用户推荐合适的产品.该过程可视为一个多准则决策问题.为了对产品集 $A = \{a_i | i = 1, 2, \dots, m\}$ 中的产品进行排名,需要从用户生成内容挖掘出产品 a_i 在准则 $c_j \in C = \{c_j | j = 1, 2, \dots, n\}$ 上的评价值 $g_j(a_i)$,通过聚合准则权重 w_j 与 $g_j(a_i)$ 得到产品综合表现值 $U(a_i)$,基于 $U(a_i)$ 的排序对产品进行排序推荐.在该决策过程中,用户的个性化偏好主要体现在基于个人偏好信息计算的准则权重的个性化.

为了获得产品评价信息,可采用自然语言处理技术从用户生成内容中挖掘用户关注的产品准则及其评价值.然而,由于用户生成内容的非结构化以及质量参差不齐,现有研究使用的情感分析算法,如Stanford NLP^[4]、TextBlob^[8]与基于词典的方法^[10],此类方法的训练数据集过时或所用方法无法捕捉上下文语义信息使得情感分类结果存在偏差,导致无法准确获取产品评价信息.如何减少从用户生成内容中挖掘产品评价信息的偏差仍是值得研究的话题.

在获取用户的产品评价信息后,可以基于用户偏好信息挖掘准则权重 w_j 并进行产品排序推荐.准则权重可通过贝叶斯偏好分解模型分解用户提供的偏好信息获取产品 a_i 在准则 c_j 上的表现值的边际值

函数 $u_j(g_j(a_i))$ 的映射关系得到.用户的偏好信息包括确定型产品偏好信息 Q^N (某一产品严格优于另一产品的成对比较集合)、不确定型产品偏好关系 Q^P (某一产品有一定几率优于另一产品的成对比较集合)和准则偏好信息 Q^C (某一准则优于另一准则的成对比较集合).当用户提供的偏好信息有限且用户偏好存在不确定性时,如何推荐符合用户偏好的产品尚缺乏研究.

为解决以上问题,提出一个结合深度学习和贝叶斯偏好分解方法的产品排序推荐模型.该模型包括两部分:1)考虑到预训练模型在泛化学习和复杂文本处理方面的优势,开发基于预训练大语言模型的情感分析方法,减少从用户生成内容中挖掘产品评价信息的偏差;2)提出基于贝叶斯偏好分解方法的产品排序推荐模型处理有限且不确定的偏好信息.具体思路包括:在对用户生成内容进行预处理后,利用BERTopic挖掘文本评论的主题和对应关键词,使用LoRA微调Chinese-RoBERTa预训练模型进行评论情感分析,获得产品的准则评价值;根据用户提供的准则偏好和不确定的产品偏好信息,构建贝叶斯偏好分解模型,分解出兼容偏好信息的值函数,计算准则权重;结合产品准则评价值和准则权重集成得到综合表现值,基于产品综合表现值的排序概率分布给出产品排序推荐方案.本文使用的数学符号及其含义如表1所示.

表1 数学符号及其含义

符号	定义
$A = \{a_i i = 1, 2, \dots, m\}$	候选产品集合.
$C = \{c_j j = 1, 2, \dots, n\}$	评价准则集合.
$W = \{w_j j = 1, 2, \dots, n\}$	准则权重集合.
$g_j(a_i)$	候选产品 a_i 在准则 c_j 上的表现值.
$u_j(g_j(a_i)) \in [0, 1]$	候选产品 a_i 在准则 c_j 表现值的边际值函数,该函数具有单调非减的性质.
$U(a_i)$	产品 a_i 的整体表现值, $U(\cdot)$ 为值函数.
$I_{Het} = \{I_{Crisp}, I_{PLTS}\}$	多准则产品评价信息,包括精确值评价信息: I_{Crisp} 和概率语言术语集合评价信息 I_{PLTS} .
$Q^N = \{q_x x = 1, 2, \dots, d\}$	确定型偏好信息集合.每个元素代表产品之间的偏好顺序 $q_x = (a_{x_1} \succ^N a_{x_2}) \in A \times A$.
$Q^P = \{q_x x = d+1, d+2, \dots, o\}$	不确定型偏好信息集合.每个元素代表产品之间以概率 pro 存在的可能偏好顺序 $q_x = (a_{x_1} \succ^P a_{x_2}, pro) \in A \times A$.
Q^C	准则间的偏好信息集合 $q_c = (c_j \succ c_k) \in C \times C, j, k = 1, 2, \dots, n, j \neq k$

1.2 用户生成内容挖掘

1.2.1 用户生成内容收集与预处理

利用Python编写网络爬虫程序,抓取在线平台上的用户生成内容,包括文本形式的产品评论和产品价格等非结构化数据.利用Jieba软件包对文本评论进行预处理,包括分词、删除特殊字符等.

1.2.2 评论主题挖掘

与传统的LDA或非负矩阵分解等方法相比,

BERTopic结合深度学习的语义嵌入与传统聚类方法,利用预训练模型生成文本的高维语义表示,能够捕捉词汇和句子之间的上下文关系及深层含义,更适合于评论文本的主题挖掘.因此,采用BERTopic^[19]主题模型挖掘评论中蕴含的主题与对应的关键词.

评论主题挖掘主要步骤包括:1)文本向量化表示.利用SentenceTransformer^[22]加载预训练的中文文本向量表示模型“text2vec-base-chinese”,将评论

文本用高维向量表示,为主题挖掘和聚类分析提供基础;2)主题模型的结构调整.基于加载的预训练模型构建 BERTopic 中文主题模型.默认的聚类算法由于无法指定聚类数量会生成大量主题及对应主题词,从中提取用户关注的产品评价准则和关键词变得极为困难.采用可以精确控制聚类数量的 K-means 算法替换默认的聚类算法,分析有限数量的聚类结果;3)主题挖掘与聚类.利用构建好的 BERTopic 主题模型对评论数据进行主题挖掘和关键词聚类;4)聚类结果迭代优化.根据主题挖掘结果去除输入数据中的无用词组,提升聚类效果.重复步骤 1)和 3)确保主题挖掘与关键词聚类的有效性.根据聚类结果分析主题和关键词,并对关键词相似度超过 60% 的聚类进行人工合并,明确提取评价准则的主题与关键词.

1.2.3 情感分析与结果表示

首先,对评论文本进行子句分割,定位包含评论准则主题词的字句,选取部分子句进行人工标注.相比于全模型微调,LoRA 在微调预训练模型过程中只需更新部分参数,既节省计算资源与时间,又能保证情感分析的准确率.因此,基于 Chinese-RoBERTa-wwm-ext^[21] 预训练模型,利用 LoRA^[20] 在标注的文本评论数据上微调预训练模型,将微调好的模型用于分析未标注评论文本的情感强度.

为区分相同情感极性但不同强度的评论文本,将情感分析的结果分为五个级别,即, {1: 非常消极; 2: 消极; 3: 中立; 4: 积极; 5: 非常积极}.为表征语言评价信息的不确定性,准则的评价值由概率语言术语集表示.任意一个准则评价值的概率语言术语集的获取步骤为:1)分析所有包含该准则关键词的评论语句的情感等级;2)统计该准则下 5 类情感等级的数量.3)计算该准则下不同的情感等级的数量占比,结果为该准则评价值的概率语言术语集.概率语言术语集的定义如式(1)^[23],其中, $p_{\alpha l} \geq 0$ 是语言术语 $s_{\alpha l}$ 的概率, L 是 $h_s(p)$ 中语言术语的数量.当 $\sum_{l=1}^L p_{\alpha l} < 1$ 时,概率语言术语集中存在缺失信息.此时,为了计算方便,可将其归一化为 $\hat{h}_s(p) = \{s_{\alpha l}(\hat{p}_{\alpha l}) | \sum_l \hat{p}_{\alpha l} = 1\}$, 其中 $\hat{p}_{\alpha l} = p_{\alpha l} / \sum_l p_{\alpha l}$, $l = 1, 2, \dots, L$.

$$h_s(p) = \{s_{\alpha l}(p_{\alpha l}) | s_{\alpha l} \in S, p_{\alpha l} \geq 0, l = 1, 2, \dots, L, \sum_{l=1}^L p_{\alpha l} \leq 1\} \quad (1)$$

语言标度函数可以表示语言术语对应的情感强度.不同标度等级的情感强度变化趋势是非均匀的.

假设情感强度的变化幅度在两极时随着等级的增加(减小)变化地更缓慢.标度函数 $f(s_{\alpha})$ 定义为式(2)^[24],其中, t 和 μ 表示对正向和负向情感的风险偏好参数. t 和 μ 取值应大于 1 以确保 $f(s_{\alpha})$ 单调递增.通过式(3)计算出概率语言术语集的得分.结合 1.2.1 节中网页爬虫抓取的产品评价准则为精确数值的评价信息,构成产品各准则表现值的决策信息.

$$f(s_{\alpha}) = \frac{t^{\tau} - t^{\tau-\alpha}}{2t^{\tau} - 2} \times 1_{\{\alpha \in [1, \tau]\}} + \frac{\mu^{\tau} + \mu^{\alpha-\tau} - 2}{2\mu^{\tau} - 2} \times 1_{\{\alpha \in [\tau, 2\tau-1]\}}, \quad (2)$$

$$E(h_s(p)) = \sum_{l=1}^L (f(s_{\alpha l}) \cdot p_{\alpha l}) / \sum_{l=1}^L p_{\alpha l}. \quad (3)$$

采用概率语言术语集而非简单加权平均或区间数,是为了保留评价证据的不确定性结构.在线评论的情感识别常呈现多等级并存,同一准则下可能同时出现积极、中立、消极信号.若用加权平均压缩为点值,会使高度一致的积极与正负分化但均值相同这类评价形态在数值上不可区分,从而难以在偏好学习中体现证据可靠性差异.概率语言术语集给出各语言等级的概率质量,同时保留中心趋势与离散度,使评价信息能够以概率形式进入贝叶斯推断并传播到值函数与排序分布,避免评价表达与不确定偏好表述之间的语义断裂.相比之下,区间数多体现为上下界或范围宽度,难以表达多峰或偏态等分布结构,进入概率推断链条往往还需额外引入分布假设.因此,概率语言术语集在表达层面与不确定性偏好表述内在一致,更适用于后续的贝叶斯偏好分解与排序概率推断.

1.3 贝叶斯偏好分解模型

在通过自然语言处理技术获得产品的准则评价价值之后,结合准则权重可计算产品综合表现值,根据产品综合表现值排名可向用户进行产品排序推荐.

为向用户精准推荐符合其偏好的产品,可与用户交互收集其间接的准则偏好信息与产品偏好信息,根据用户偏好信息构建贝叶斯偏好分解模型并利用马尔可夫链蒙特卡洛方法推断满足用户偏好的准则权重概率分布,再结合产品的准则评价价值计算产品综合表现值排序的概率分布,从而为用户进行产品排序推荐.

1.3.1 偏好分解模型

偏好分解模型能根据用户提供的偏好信息通过数学规划模型抽取符合用户偏好的准则边际值函数及准则权重.在经典的偏好分解模型中,加性值函数为各个准则的边际值之和,即, $U(a_i) =$

$\sum_{j=1}^n u(g_j(a_i))^{[25]}$. 本研究采用分段线性边际值函数来表示值函数, 因为它能通过足够数量的子区间拟合任何形式的非线性边际值函数. 分段线性边际值函数可以通过不同的函数类型 (如凹型、线性和凸型) 反映决策者的不同风险态度 (如风险厌恶和风险偏好)^[26]. 令 $X_j = [\underline{x}_j, \bar{x}_j]$ 为准则 c_j 下产品的表现值范围, 其中, \underline{x}_j 和 \bar{x}_j 分别是准则 c_j 下所有产品的最低和最高表现值. 将 X_j 分为 $\alpha_j \geq 1$ 个相等的子区间: $[\underline{x}_j = x_j^0, x_j^1], [x_j^1, x_j^2], \dots, [x_j^{\alpha_j-1}, x_j^{\alpha_j} = \bar{x}_j]$, 其中, $x_j^t = \underline{x}_j + \frac{t}{\alpha_j}(\bar{x}_j - \underline{x}_j), t = 0, 1, \dots, \alpha_j$. 使用线性插值法估计准则 c_j 下产品 a_i 的边际值, 见式 (4).

$$u_j(g_j(a_i)) = u_j(x_j^t) + \frac{g_j(a_i) - x_j^t}{x_j^{t+1} - x_j^t} (u_j(x_j^{t+1}) - u_j(x_j^t)),$$

$$\text{当 } g_j(a_i) \in [x_j^t, x_j^{t+1}] \quad (4)$$

$$\text{令 } \Delta u_j^t = u_j(x_j^t) - u_j(x_j^{t-1}), t = 1, 2, \dots, \alpha_j,$$

则式 (4) 可表示为 $u_j(g_j(a_i)) = \sum_{t=1}^{\alpha_j} \Delta u_j^t + \frac{g_j(a_i) - x_j^t}{x_j^{t+1} - x_j^t} \Delta u_j^{t+1}$, 当 $g_j(a_i) \in [x_j^t, x_j^{t+1}]$. 对于每个准则, 定义向量 $\mathbf{u}_j = (\Delta u_j^1, \dots, \Delta u_j^{\alpha_j})^T$, 根据偏好分解模型定义, 权重 $w_j = \sum_{t=1}^{\alpha_j} \Delta u_j^t, \forall j$.

对于每个 $t = 1, 2, \dots, \alpha_j$, 定义向量 $\mathbf{V}_j(a_i) = (v_j^1(a_i), \dots, v_j^{\alpha_j}(a_i))^T$, 其中,

$$v_j^t(a_i) = \begin{cases} 1, & \text{当 } g_j(a_i) > x_j^t \\ \frac{g_j(a_i) - x_j^{t-1}}{x_j^t - x_j^{t-1}}, & \text{当 } x_j^{t-1} \leq g_j(a_i) \leq x_j^t \\ 0, & \text{当 } g_j(a_i) < x_j^{t-1} \end{cases} \quad (5)$$

根据 \mathbf{u}_j 和 $\mathbf{V}_j(a_i)$, 准则的边际值可表示为 $u_j(g_j(a_i)) = \mathbf{u}_j^T \mathbf{V}_j(a_i)$. 对于所有准则, 令 $\mathbf{u} = (\mathbf{u}_1^T, \dots, \mathbf{u}_n^T)^T$ 和 $\mathbf{V}(a_i) = (\mathbf{V}_1(a_i)^T, \dots, \mathbf{V}_n(a_i)^T)^T$, 则备选产品的综合价值函数可表示为 $U(a_i) = \mathbf{u}^T \mathbf{V}(a_i)$. 其中, $\mathbf{V}(a_i)$ 可根据准则表现值 $g_j(a_i)$ 与所属于区间直接计算得到, 向量 \mathbf{u} 则需通过求解满足偏好关系约束的偏好分解模型^[25] 得到.

1.3.2 贝叶斯视角下的偏好分解模型

经典的偏好分解模型需要复杂的后验分析过程处理可能存在的非一致偏好信息. 为解决该问题, 将贝叶斯规则融入偏好分解模型中, 构建贝叶斯偏好分解模型求解所有可能的准则边际值函数, 进而推断值函数 U 的分布.

贝叶斯偏好分解模型根据产品偏好信息集合 Q^N 和 Q^P , 定义表征确定与不确定偏好信息的似然函数 $P(Q^N, Q^P|U)$ 与值函数 U 服从的先验分布 $P(U)$, 通过贝叶斯规则估计一定限制条件 (先验信息) 下的值函数 U 的后验分布 $P(U|Q^N, Q^P)$. 根据贝叶斯公式, 值函数 U 的后验分布定义为式 (6), 其中, $P(Q^N, Q^P)$ 为标准化因子, 确保后验概率 $P(U|Q^N, Q^P)$ 是一个有效的概率值, 并且所有可能假设的后验概率之和等于 1. 式 (6) 中各部分的数学表达式将在后续小节介绍.

$$P(U|Q^N, Q^P) = \frac{P(Q^N, Q^P|U)P(U)}{P(Q^N, Q^P)}. \quad (6)$$

1.3.3 似然函数

首先介绍不同类型偏好关系下似然函数的定义. 假设产品之间存在以下偏好关系: 1) 确定型偏好关系 Q^N : 产品 a_{x_1} 严格优于产品 a_{x_2} , 表示为 $a_{x_1} \succ^N a_{x_2}$. 2) 不确定型偏好关系 Q^P : 产品 a_{x_1} 有 pro 的概率优于产品 a_{x_2} , 表示为 $a_{x_1} \succ^P a_{x_2}(pro)$. 为表征以上偏好关系, 分别定义以下两种似然函数:

1) 确定的偏好关系:

$$P(a_{x_1} \succ^N a_{x_2} | U) = \text{Bernoulli}(z_{x_1, x_2}) = \begin{cases} 1, & \text{当 } U(a_{x_1}) > U(a_{x_2}) \\ 0, & \text{当 } U(a_{x_1}) \leq U(a_{x_2}) \end{cases} \quad (7)$$

2) 不确定的偏好关系:

$$P(a_{x_1} \succ^P a_{x_2} | U) = \frac{(pro \times \lambda \times e)^{U(a_{x_1})}}{(pro \times \lambda \times e)^{U(a_{x_1})} + (pro \times \lambda \times e)^{U(a_{x_2})}} = \frac{1}{1 + \exp(-pro \times \lambda \times (U(a_{x_1}) - U(a_{x_2})))}. \quad (8)$$

$$P(Q^N, Q^P | U) = \prod_{x=1}^o P(a_{x_1} \succ a_{x_2} | U) = \frac{\prod_{x=1}^d \text{Bernoulli}(z_{x_1, x_2}) \prod_{x=d+1}^o 1}{1 + \exp(-pro \times \lambda \times (U(a_{x_1}) - U(a_{x_2})))} \quad (9)$$

式 (7) 利用伯努利分布^[18] 表示当两个产品之间存在确定的偏好关系 $a_{x_1} \succ^N a_{x_2}$ 时, 即当前值函数 U 下, $U(a_{x_1}) > U(a_{x_2})$, 则 $P(a_{x_1} \succ a_{x_2} | U) = 1$; 当 $a_{x_2} \succ^N a_{x_1}$ 时, $P(a_{x_1} \succ a_{x_2} | U) = 0$.

式 (8) 通过多项逻辑模型的变体^[17] 表示当两个产品之间存在不确定的偏好关系 $a_{x_1} \succ^P a_{x_2}(pro)$ 时, 通过 $U(a_{x_1})$ 与 $U(a_{x_2})$ 之间的差异以及概率 pro 表

示 $a_{x_1} \succ a_{x_2}$ 的概率. 其中, λ 为函数凹凸程度的控制参数, λ 越小, 当 $U(a_{x_1})$ 大于 $U(a_{x_2})$ 的值越小时, $P(a_{x_1} \succ a_{x_2} | U)$ 越小, 即, a_{x_1} 优于 a_{x_2} 的概率也越小.

式 (9) 通过结合两类偏好关系的似然函数 (7) 和 (8), 构建考虑确定和不确定两类产品偏好信息的综合似然函数.

1.3.4 值函数先验分布

为计算贝叶斯模型的后验概率, 还需定义值函数服从的先验分布. 为保证值函数的单调性并将值函数 U 的取值归一化到 $[0,1]$ 区间内, 定义约束条件如式 (10), 其中, $\mathbf{0}$ 和 $\mathbf{1}$ 分别表示所有元素均为 0 和 1 的向量.

$$\begin{cases} \mathbf{u}^T \mathbf{1} \\ \mathbf{u} \geq 0 \end{cases} \quad (10)$$

由于 Dirichlet 分布能够确保 \mathbf{u} 中所有元素取值非负且和为 1, 满足偏好分解准则效用函数单调非减的假设, 因此, 选择式 (11) 所示的 Dirichlet 分布作为

值函数 U 的先验分布^[17], 其中, $B(\boldsymbol{\varphi}) = \frac{\prod_{r=1}^R \Gamma(\varphi_r)}{\Gamma(\sum_{r=1}^R \varphi_r)}$ 是

归一化因子, 参数 $\boldsymbol{\varphi} = \{\varphi_r | r = 1, 2, \dots, R\}$ 控制 Dirichlet 分布生成参数 \mathbf{u} , R 为参数 \mathbf{u} 的维度, $\Gamma(\cdot)$ 为伽马函数.

$$P(\mathbf{u}) = \text{Dir}(\mathbf{u} | \boldsymbol{\varphi}) = \frac{1}{B(\boldsymbol{\varphi})} \prod_{r=1}^R u_r^{\varphi_r - 1} \quad (11)$$

1.3.5 考虑用户准则偏好先验信息的先验分布

本节通过示例介绍如何将用户的准则偏好信息融入到先验分布之中, 控制生成的准则边际值函数 \mathbf{u} 满足用户的准则偏好.

例 1 假设用户提供以下两类准则偏好信息: 1) 准则 c_1 的重要性高于准则 c_2 ; 2) c_3 是最重要的准则, c_4 是最不重要的准则. 将用户提供的准则偏好信息表达为式 (12), 通过蒙特卡洛模拟在式 (12) 的限制下生成准则 c_j 的权重 w_j , 结合 α_j 的数量计算每个子区间的占比 $\gamma_j = \frac{w_j}{\alpha_j}$, 对所有 γ_j 乘以 $\min\{1/\gamma_j\}$ 进行缩放, 使得最小的 γ_j 为 1. 缩放后 γ_j 的集合为先验信息 $\boldsymbol{\varphi}$, 输入到 Dirichlet 分布中控制参数 \mathbf{u} 的生成^[17]. 当 $n = 4, \alpha_j = 3, \forall j$ 时, 假设模拟得到 $w_j = [0.2, 0.3, 0.4, 0.1]$, 则 $\gamma_j = [\frac{1}{15}, \frac{1}{15}, \frac{1}{15}, \frac{1}{10}, \frac{1}{10}, \frac{1}{10}, \frac{2}{15}, \frac{2}{15}, \frac{2}{15}, \frac{1}{30}, \frac{1}{30}, \frac{1}{30}]$, 将 γ_j 乘 $\min\{1/\gamma_j\} = 30$, 可得 $\boldsymbol{\varphi} = [2, 2, 2, 3, 3, 3, 4, 4, 4, 1, 1, 1]$.

$$\begin{cases} w_1 \geq w_2 \\ w_3 \geq w_j, \forall j \setminus 3 \\ w_j \geq w_4, \forall j \setminus 4 \\ \sum_{j=1}^n w_j = 1 \end{cases} \quad (12)$$

1.3.6 基于马尔科夫链蒙特卡洛方法的抽样过程

由于值函数的先验分布与偏好信息的似然分布不共轭, 不存在封闭形式的解来计算值函数的后验分布, 这导致式 (6) 的后验分布无法通过解析方法进行计算. 因此, 采用马尔科夫链蒙特卡洛方法求解所提出的贝叶斯模型. 本节介绍贝叶斯偏好模型的求解过程.

鉴于模型参数维度较小, Metropolis-Hastings 算法被用来从构建的后验分布中抽样^[27]. Metropolis-Hastings 算法是一种从概率分布中生成样本的马尔科夫链蒙特卡洛方法. 该算法主要思路为, 设置一个提议分布 $pd(\mathbf{u}_{old}, \mathbf{u}_{new})$ 来决定从旧状态 \mathbf{u}_{old} 向新状态 \mathbf{u}_{new} 的移动. 提议分布是当前状态下 \mathbf{u}_{old} 的条件概率分布, 用来确定下一个状态 \mathbf{u}_{new} . 考虑到旧状态与新状态之间的独立性, 且参数天然位于概率单纯形上, 需满足非负性与和为 1 的约束. 若使用常规高斯随机游走, 不仅需要额外的投影或截断以维持可行性, 还会在边界附近产生较强的反射效应, 导致提议失真与接受率下降, 因此选择式 (13) 所示的 Dirichlet 分布为提议分布. Dirichlet 提议分布能降低可行性维护成本并改善边界区域的采样稳定性, 在权重类单纯形参数的后验采样中通常能获得较好的混合表现, 但需要通过调节浓度参数或采用分块更新来避免步长过小导致的慢混合问题, 从而在接受率与全局探索之间取得更优平衡. 在 Metropolis-Hastings 算法的循环中, 先从提议分布中抽取新状态 \mathbf{u}_{new} , 再根据式 (14) 计算从旧状态 \mathbf{u}_{old} 移动到新状态 \mathbf{u}_{new} 的概率, 根据概率的大小选择是否接受此次移动. 由式 (6) 可得, $P(\mathbf{u} | Q^N, Q^P) \propto P(\mathbf{u}) P(Q^N, Q^P | \mathbf{u})$, 则 $p(\mathbf{u}_{old}, \mathbf{u}_{new})$ 可表示为式 (15).

$$pd(\mathbf{u}_{old}, \mathbf{u}_{new}) = \text{Dir}(\mathbf{u}_{new} | \mathbf{1}), \quad (13)$$

$$p(\mathbf{u}_{old}, \mathbf{u}_{new}) = \min\left\{1, \frac{\text{Dir}(\mathbf{u}_{old} | \mathbf{1}) P(\mathbf{u}_{new} | Q^N, Q^P)}{\text{Dir}(\mathbf{u}_{new} | \mathbf{1}) P(\mathbf{u}_{old} | Q^N, Q^P)}\right\}. \quad (14)$$

$$p(\mathbf{u}_{old}, \mathbf{u}_{new}) = \min\left\{1, \frac{\text{Dir}(\mathbf{u}_{old} | \mathbf{1}) \text{Dir}(\mathbf{u}_{new} | \boldsymbol{\alpha}) P(Q^N, Q^P | \mathbf{u}_{new})}{\text{Dir}(\mathbf{u}_{new} | \mathbf{1}) \text{Dir}(\mathbf{u}_{old} | \boldsymbol{\alpha}) P(Q^N, Q^P | \mathbf{u}_{old})}\right\}. \quad (15)$$

所提出求解贝叶斯偏好分解模型的 Metropolis-

Hastings 算法步骤如算法 1 所示. 在 Metropolis-Hastings 算法中, 马尔科夫链需先进行 $Iter_{sta}$ 次数的迭代以达到稳态分布. 达到稳态分布后, 后续的 $Iter$ 次迭代结果为有效样本. 根据 $Iter$ 次迭代中 \mathbf{u} 的样本结果, 采用式 (16) 计算排名接受指数 (RAI), 该指数反映产品 a_i 被排在第 r 位的可能性. 其中, $S_{a_i, r} \in S$ 表示使产品 a_i 排在第 r 名的抽样值函数子集, $|S_{a_i, r}|$ 表示集合 $S_{a_i, r}$ 中的元素个数. 根据每个产品在不同排名下最大的 RAI 值生成候选产品排序, 并给出产品排序推荐建议.

$$RAI(a_i, r) = \frac{|S_{a_i, r}|}{Iter}. \quad (16)$$

算法 1 求解贝叶斯偏好分解模型的 Metropolis-Hastings 算法

输入 : $Q = \{Q^N, Q^P, Q^C\}$, $I_{Het} = \{I_{Crisp}, I_{PLTS}\}$, $Iter, Iter_{sta}$

输出: \mathbf{u} 的抽样结果集合 \mathbf{u}^*

1: 根据用户给出的准则偏好关系 Q^C , 构建如式 (12) 所示的限制空间, 利用蒙特卡洛模拟生成 w_j , 进而计算初始的 φ .

2: 随机生成马尔科夫链的初始状态 $\mathbf{u}_0 \sim \text{Dir}(\mathbf{u}|\varphi)$.

3: **for** $i = 1: Iter_{sta} + Iter$ **do** #开始循环

4: $\mathbf{u}_{old} = \mathbf{u}_0$ #初始化

5: 基于评价信息 $I_{Het} = \{I_{Crisp}, I_{PLTS}\}$ 和公式 (5) 计算 $\mathbf{V}(a)$.

6: 生成新状态 $\mathbf{u}_{new} \sim \text{Dir}(\mathbf{u}|\varphi)$.

7: 根据式 (15) 计算接受概率 $p(\mathbf{u}_{old}, \mathbf{u}_{new})$.

8: **if** $p(\mathbf{u}_{old}, \mathbf{u}_{new}) < \text{random}(0, 1)$ **do**

9: $\mathbf{u}_{i+1} = \mathbf{u}_{new}$

10: **else**

11: $\mathbf{u}_{i+1} = \mathbf{u}_{old}$

12: **end if**

13: **end for**

14: **Return** 抽样结果 $\mathbf{u}^* = \{\mathbf{u}_{Iter_{sta}+1}, \dots, \mathbf{u}_{Iter}\}$

2 案例分析

为验证所提出的产品排序推荐模型的有效性, 以 JD 在线购物平台的同类型医疗手环为例进行个性化产品排序推荐.

2.1 数据获取与情感分析

使用 Python 编写网页爬虫程序抓取 JD.com 上 17 款同类医疗手环的产品价格与从产品上架至 2024 年 9 月 25 日的所有评论, 共计 10900 条. 通过数据预处理, 筛除评论长度小于 5 字以及重复的评论, 去除文本中的乱码和干扰符号, 最终剩余 8064 条评

论. 利用 1.2.2 节的主题模型进行文本主题挖掘与聚类. 其中, 通过计算聚类数量 K 从 5 到 12 的平均轮廓系数值 (5: 0.0460, 6: 0.0410, 7: 0.0423, 8: 0.0454, 9: 0.0452, 10: 0.0473, 11: 0.0351, 12: 0.0403) 与连贯分数值 (7: 0.5614, 8: 0.5829, 9: 0.5616, 10: 0.5909, 11: 0.5703) 可得, K 为 10 时两指标的值最大. 因此, 聚类数量设为 10, $n\text{-grams}$ 的范围为 2. 根据聚类结果发现, 聚类中主题词重复度超过 60% 的聚类属于同一类主题, 另外部分词汇属于不包含有效意见信息, 因此合并相似主题聚类, 最终获得 4 个聚类. 4 个聚类代表的准则与对应关键词如表 2 所示.

表2 主题聚类结果及对应关键词

主题	关键词
c_1 : 功能与操作性	质量, 功能, 数据, 检测, 测试, 测量, 无创, 效果, 精准, 操作, 使用, 人性化, 灵敏度, 老人, 屏幕, 品质, 性价比, 质感, 品质
c_2 : 外观与舒适性	外观, 外形, 款式, 做工, 佩戴, 包装, 外形, 设计, 颜值, 轻巧, 舒适程度
c_3 : 续航与耐用性	充电, 续航, 超长, 耐用, 电池, 耗电, 电量
c_4 : 物流与售后服务	物流, 服务, 服务态度, 发货, 配送, 运送, 快递, 客服, 卖家, 发货速度, 店家

根据提取出的关键词, 定位对应的评论. 将评论分解成多个子句, 总计 25763 条. 选择其中 5000 条 (每种准则选择 1250 条) 子句进行情感等级标注, 其中, 80% 用于训练, 20% 用于验证. 基于 LoRA 框架, 利用标注数据微调 Chinese-RoBERTa-wwm-ext 情感分类模型. 其中, 模型训练参数设置为: LoRA 的秩为 8, 缩放因子为 16, $dropout$ 比例为 0.1, 模型学习率为 $2e-5$, 训练与验证的 $batch_size$ 为 16, $epoch$ 为 5, 优化器为 AdamW. 经过 10 次对数据集随机分隔的实验得到情感分析结果, 如表 3 所示. 与全量微调的 Chinese-RoBERTa-wwm-ext、LoRA 微调的 BERT、双向长短期记忆神经网络 (BiLSTM^[10])、支持向量机^[28]、朴素贝叶斯方法^[28] 和 SnowNLP 等方法在同一数据划分与评价指标下进行对比, 本文方法在准确率、召回率与 F1 值等指标上整体表现优于除全量微调 Chinese-RoBERTa-wwm-ext 之外的多数基线模型. 尽管全量微调 Chinese-RoBERTa-wwm-ext 在综合指标上略占优势, 本文采用的 LoRA 方案在相同硬件与训练设置下显著降低了训练时间与显存占用 (训练时长约为全量微调的 2/3), 体现出更优的效率-效果权衡. 本文方法能够在较低计算成本下获得较高的情感分类性能, 提升评价信息抽取的可靠性, 为后续产品排序推荐模型提供稳定的数据输入.

表3 情感分类算法对比结果

方法	准确率	召回率	F1值
SnowNLP	0.3031	0.3129	0.3079
SVM	0.6473	0.6080	0.6270
NB	0.6307	0.6217	0.6265
BiLSTM	0.7519	0.7358	0.7437
全量微调Chinese RoBERTa	0.9167	0.9015	0.9090
LoRA-BERT	0.8913	0.8826	0.8869
LoRA-Chinese RoBERTa	0.9025	0.8971	0.8998

利用训练后的分类模型对剩余子句进行情感分析,得到所有产品准则关键词的情感得分.计算17款产品同一准则下的不同情感等级的数量比例并用概率语言术语集表示.以产品 a_1 为例,其情感分析结果如下:

$$PLTS(a_1) = \left(\begin{array}{l} c_1: \{s_1(0), s_2(0.25\%), s_3(1.44\%), s_4(14.99\%), \\ s_5(82.31\%)\} \\ c_2: \{s_1(0.81\%), s_2(1.75\%), s_3(7.67\%), \\ s_4(19.65\%), s_5(70.21\%)\} \\ c_3: \{s_1(0), s_2(0), s_3(1.93\%), s_4(20.29\%), \\ s_5(77.78\%)\} \\ c_4: \{s_1(0.53\%), s_2(0.13\%), s_3(1.11\%), \\ s_4(2.74\%), s_5(95.43\%)\} \end{array} \right)$$

除表2所示的准则外,通过爬虫获取的成本型准则产品价格 c_5 也被列入到医疗手环评价准则中,其值为: $c_5(a_i): \{998, 429, 698, 1280, 2160, 1749, 1680, 1680, 1880, 899, 2180, 598, 1749, 858, 698, 698, 898\}$.利用式(2)和(3)计算产品的准则得分,其中, $\mu = t = 2$.结合价格准则值,构建产品完整的准则评价信息.以 a_1 为例,该产品在前准则 c_1 到 c_4 上的情感得分为 $I_{PLTS} = \{0.9411, 0.8764, 0.9227, 0.9786\}$,在价格 c_5 的取值为 $I_{Crisp} = \{998\}$,则 $I_{Het} = \{I_{PLTS}, I_{Crisp}\} = \{0.9411, 0.8764, 0.9227, 0.9786, 998\}$.

2.2 案例求解

在获取产品完整准则评价信息之后,假设通过交互当前用户给出以下偏好信息:1) 准则偏好关系:功能与操作性(c_1)是最重要的准则,外观与舒适度(c_2)最不重要,价格(c_5)要比物流服务(c_4)更重要, $Q^C = \{c_1 \succ c_2, c_1 \succ c_3, c_1 \succ c_4, c_1 \succ c_5, c_3 \succ c_2, c_5 \succ c_4\}$.2) 根据JD.com给出的排行榜与从用户交互获取的产品偏好信息,得到以下三组确定与不确定的产品偏好关系: $Q^N = \{a_1 \succ a_3, a_9 \succ a_6, a_{17} \succ a_{16}\}$, $Q^P = \{a_4 \succ a_2(60\%), a_5 \succ a_{15}(70\%), a_3 \succ a_6(50\%)\}$.基于用户给出的偏好关系,利用算法1求解贝叶斯偏好分解模型,计算所有可能的价值函数,其中,区间数量^[29] $\alpha_j = 5, \forall j$,控制参数 $\lambda = 5$,马尔科夫链数量

设置为4,马尔科夫链达到稳态分布的抽样次数($Iter_{Sat}$)设置为100次,后续的有效抽样次数($Iter$)设置为10000次.

马尔科夫链的收敛性通过Gelman-Rubin统计量(\hat{R})和有效样本量进行评估.结果显示,4条链的 \hat{R} 值接近1(最小/中位/最大=1.0000/1.0001/1.0006),且有效样本量为(最小/中位/最大=10151/11266/14294),表明模型已充分收敛,后验推断可靠.图1为贝叶斯模型对数后验概率的迹线图.由图1可见,在100次抽样后,贝叶斯模型对数后验概率的迹线图表现出杂乱无序,说明马尔科夫链已经收敛.图1中的虚线(100次)为burn-in时期(左)与正式抽样时期(右)的分界线,右上角为burn-in时期的迹线.图2中自相关系数在滞后小于5时快速降低,表明马尔科夫链已经接近平稳分布,可认为马尔科夫链已经收敛.因此,后续的抽样结果为有效数据.

每一次采样 \mathbf{u} 之后,计算准则权重.结合产品准则值利用加权平均算子聚合得到当前迭代次数下产品的综合表现值,基于综合表现值对产品排序.算法循环完毕后,通过式(16)计算产品排序的RAI值,结果如图3所示.图3以颜色深浅表示各产品在不同名次上的RAI值,颜色越深代表该产品在马尔科夫链蒙特卡洛抽样中越频繁出现在对应名次.热力图结果表明,排名稳定性呈现显著的结构分化: a_{10} 在99.72%的抽样中保持第1位, a_6 在92.99%的抽样中保持第17位,说明头部与尾部存在高度稳定的锚点名次;同时,第2位(a_1 的RAI为53.51%)、第6位(a_4 的RAI为50.25%)与第7位(a_{14} 的RAI为60.46%)也表现出单一产品主导的稳定格局.相比之下,排名波动主要集中在第8到第13位区间,多数产品在多个相邻名次上具有非零RAI值,表明其综合表现更接近、对准则权重扰动更敏感.进一步统计发现,产品 a_1, a_4, a_6, a_{10} 和 a_{14} 的RAI非零位置数量均值为7.2,显著小于其余产品的12.75,说明前者的排名概率质量更集中,而后者的排名分布更分散,从而导致名次波动更大.

计算所有产品的RAI值之后,根据每个排名下RAI值最高的产品以及每个产品最可能的排名位置(产品RAI值最高的排名)给出相应的产品排序,结果为 $a_{10} \succ a_1 \succ a_{17} \succ a_2 \succ a_{12} \succ a_4 \succ a_{14} \succ a_{15} \succ a_{11} \succ a_8 \succ a_7 \succ a_9 \succ a_5 \succ a_3 \succ a_{16} \succ a_{13} \succ a_6$.根据 \mathbf{u} 的平均值,计算准则的平均权重,结果为 $w_j = \{0.3613, 0.0347, 0.2044, 0.1461, 0.2539\}$.结合准则评价价值和权重,聚合得到产品 a_1 到 a_{17} 的综合评价值为 $\{0.7174, 0.6779, 0.3946, 0.6123, 0.4420,$

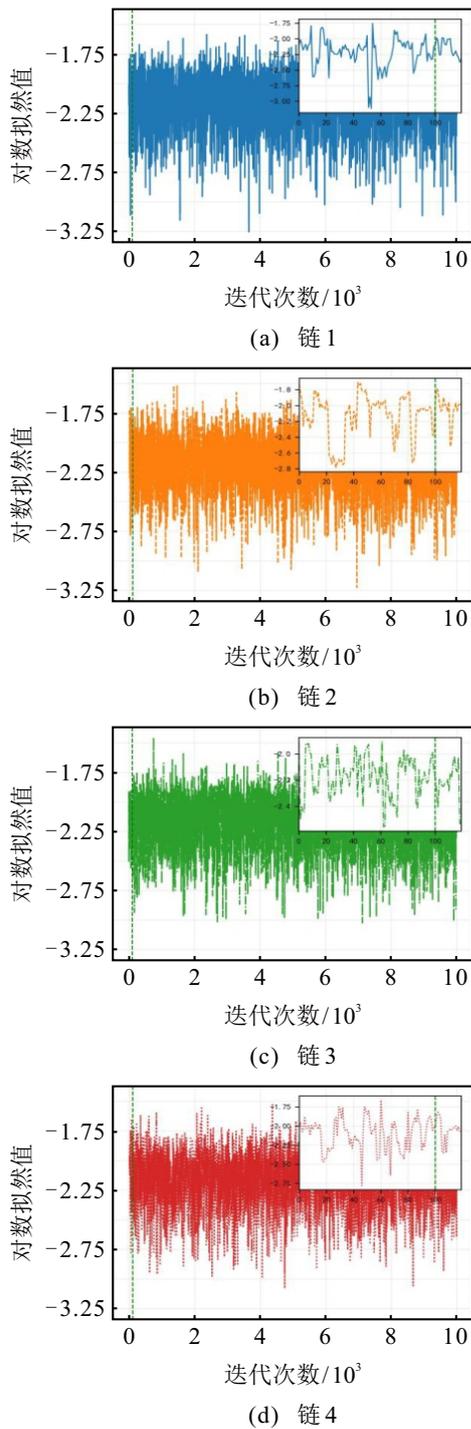


图1 贝叶斯模型对数后验概率的迹线图

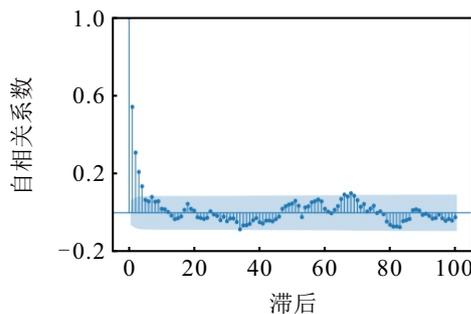


图2 贝叶斯模型对数后验概率自相关系数扰动图

0.6526, 0.3584, 0.5800, 0.5042, 0.3853, 0.6939}, 产品的排序结果为 $a_{10} \succ a_1 \succ a_{17} \succ a_2 \succ a_{12} \succ a_4 \succ a_{14} \succ a_{15} \succ a_8 \succ a_{11} \succ a_7 \succ a_9 \succ a_5 \succ a_3 \succ a_{16} \succ a_{13} \succ a_6$. 与根据综合考虑每个排名下RAI值最高的产品和每个产品最可能的排名位置得到的排序相比,所有产品的整体排名基本完全一致.产品 a_{10} 的综合表现值最大(0.8740),相比于其他产品有着显著的优势.17个产品中,仅产品 a_8 和 a_{11} 的排名存在差异,这主要由于产品 a_{11} 在所有排名中都有RAI值,但每一个排名下其RAI值均非最大.因此,在综合考虑每个排名下RAI值最高的产品和每个产品最可能的排名位置时, a_{11} 的排名波动较大,表明其综合评价受到准则权重变化的影响最大.根据求解结果,向用户推荐产品 a_{10} 作为最优选择,并给出所有产品的排序与对应的排名概率,以及准则权重的平均数值供用户参考.

2.3 敏感性分析

2.3.1 准则偏好信息敏感性分析

为验证所提方法对于准则变化的敏感性,本节对比四种不同准则偏好场景下产品的排序推荐结果.

场景0:即第2.1节的案例场景;

场景1:用户认为准则 c_1 是最重要的,准则 c_5 比准则 c_4 重要,即, $Q_1^C = \{c_1 \succ c_2, c_1 \succ c_3, c_1 \succ c_4, c_1 \succ c_5, c_5 \succ c_4\}$;

场景2:用户认为准则 c_1 比准则 c_2 重要,准则 c_5 比准则 c_3 重要,即, $Q_2^C = \{c_1 \succ c_2, c_5 \succ c_3\}$;

场景3:用户认为准则 c_4 是最不重要的,准则 c_5 比准则 c_2 重要,即, $Q_3^C = \{c_1 \succ c_4, c_2 \succ c_4, c_3 \succ c_4, c_5 \succ c_4, c_5 \succ c_2\}$.

基于场景1-3的偏好信息,模拟对应的准则权重,利用算法1求解产品的RAI值.根据4种场景下的产品RAI值分布表,产品 a_{10} 排名在第一位的RAI值始终最大,显示出显著的稳定性和优势.产品 a_6 排名在最后的RAI值始终超过69%.稳定的排名显示出产品的准则表现值较差,不易受到准则权重变化的干扰.其他产品则表现出一定的波动,如产品 a_{17} 和 a_2 (最大的RAI值变化超过30%),在不同场景中,它们的排名集中度和表现显著变化; a_{17} 在场景1中排名2的RAI值达到了91.88%, a_2 在场景1中的排名3的RAI值达到73.13%,这反映了准则权重变化对于其综合表现值的影响.此外,对于最大RAI值波动较小的产品,如产品 a_5 ,一般具有离散的RAI值分布,说明其准则表现值差异较小,当准则权重稍微变化时,其排名会发生变化.

0.2513, 0.4720, 0.4827, 0.4637, 0.8740, 0.4825,

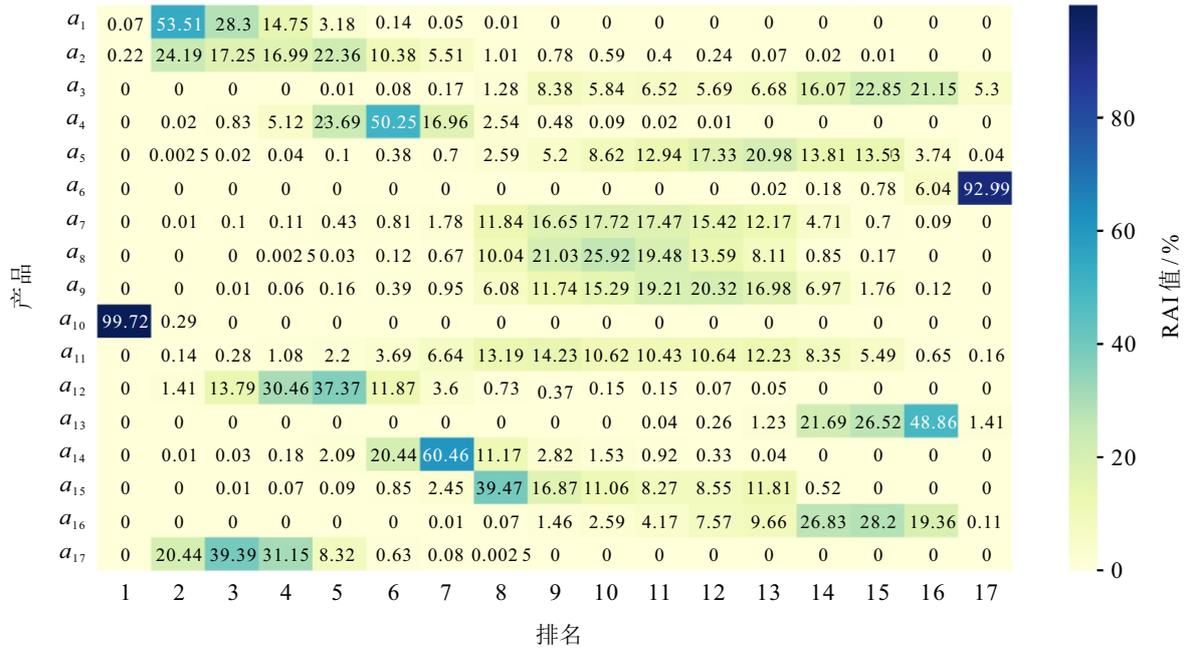


图3 产品RAI值排名

为计算平均准则权重下产品表现值,先计算 $Iter$ 次抽样后的平均准则权重,结果如图4.根据图4,除了场景2的权重分布较为均匀之外,其余场景下最小权重与最大权重的值相差超过0.25.观察不同场景下的偏好信息数量,场景2中的偏好信息数量最少,所以权重值趋近于均匀分布,说明偏好信息数量越多,对权重的限制越大,权重分布的差异越明显.从图4的准则平均权重可以看出,不同偏好场景对排序的扰动强度存在显著差异,其中场景1相对场景0的权重调整最为剧烈: c_2 (外观与舒适性)的权重由0.0347显著提升至0.2843,而 c_4 和 c_5 (物流与售后服务、价格)权重同步下降,意味着排序更容易被准则 c_2 的重视度所影响.相比之下,场景2的权重变动更均衡且幅度较小,场景3介于二者之间,这从机制上解释了为何场景1引发更明显的名次重排.总体而言,权重扰动的幅度与排序结构的变化呈现一致性,其中准则 c_2 (外观与舒适性)的权重上调幅度最大、对整体排序的敏感性最强,是驱动跨场景排序差异的关键准则.

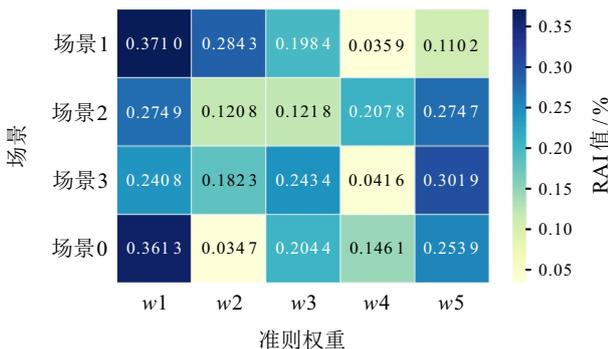


图4 不同偏好信息场景下准则的平均权重

名次变化主要集中在中游产品,且在场景1下表现得更为突出:一部分产品在场景0下处于靠前位置,但在强调外观与舒适性后出现明显下滑,另一部分产品则在该场景中获得显著上升,说明其相对优势更依赖于该准则的表现. RAI分布显示排序的两端存在稳定锚点: a_{10} 在各场景中始终以极高概率占据第1位, a_6 也在各场景中稳定处于末位,表明这两款产品的综合优势或劣势并非由单一准则驱动,而是具有跨偏好设定的稳健性.基于此,管理者可将中游、对权重变化敏感的产品作为优先诊断对象,进一步结合权重结构识别其短板维度并制定针对性改进或差异化定位策略.

结合准则评价 I_{Het} 计算产品的综合表现值与排名,结果如表4所示.表4结果显示,产品 a_6 和 a_{10} 在4种场景下的排名无任何波动,说明这两个产品的所有准则表现值与其他产品的准则表现值区别较大,权重变化对其综合表现值的排名影响不显著.而对 a_{10} 和 a_6 这类产品,则可分别作为标杆与改进底线,用于指导产品迭代与资源配置的优先级排序.

采用平均绝对排名差 $Rd = \sum_{i=1}^n |rank_1(a_i) - rank_2(a_i)|/n$ 量化不同场景下各产品的排名差异,其中, $rank_1(a_i)$ 和 $rank_2(a_i)$ 分别表示所提方法与对比方法下产品 a_i 的排序值, n 为产品总数.计算结果为:场景0与场景1、2和3之间的排名差异分别为1.765, 0.706和1.176,表明场景0与场景2之间的排序差异最小,与场景1的差异最大.计算不同偏好场景下排序结果与基准场景的 Kendall 等级相关系

表4 不同场景下产品综合表现值与排名

产品	场景1	排名	场景2	排名	场景3	排名	场景0	排名
a_1	0.5744	4	0.6962	2	0.6284	4	0.7174	2
a_2	0.6369	3	0.6571	4	0.6689	3	0.6779	4
a_3	0.3136	15	0.3831	14	0.3964	16	0.3946	14
a_4	0.5635	5	0.6023	6	0.5677	8	0.6123	6
a_5	0.4778	12	0.4022	13	0.4326	14	0.4420	13
a_6	0.2207	17	0.2588	17	0.2687	17	0.2513	17
a_7	0.5085	9	0.4707	9	0.5090	9	0.4720	11
a_8	0.5157	7	0.4683	10	0.4700	10	0.4827	9
a_9	0.4929	11	0.4647	11	0.4616	11	0.4637	12
a_{10}	0.9415	1	0.8607	1	0.8842	1	0.8740	1
a_{11}	0.5413	6	0.3698	15	0.4583	12	0.4825	10
a_{12}	0.4493	13	0.6057	5	0.6102	5	0.6526	5
a_{13}	0.4311	14	0.3232	16	0.4142	15	0.3584	16
a_{14}	0.5048	10	0.5809	7	0.5754	7	0.5800	7
a_{15}	0.5130	8	0.5025	8	0.5853	6	0.5042	8
a_{16}	0.2986	16	0.4070	12	0.4466	13	0.3853	15
a_{17}	0.7165	2	0.6718	3	0.7318	2	0.6939	3

注:表4中加粗的数字表明其对应产品的排名最高或最低.

数与 Spearman 相关性系数. 计算结果为: 场景 0 和场景 1 的 Kendall 系数 $\tau = 0.721$, Spearman 系数 $\rho = 0.863$; 场景 0 和场景 2 的 Kendall 系数 $\tau = 0.882$, Spearman 系数 $\rho = 0.951$; 场景 0 和场景 3 的 Kendall 系数 $\tau = 0.838$, Spearman 系数 $\rho = 0.958$. 结果表明, 与场景 0 相比, 场景 2 与场景 3 的排序一致性更高, 场景 1 引起的排序变化最大, 排序对该类偏好设定更敏感.

基于以上分析, 在当前候选产品集合中, 用户准则偏好的变化对产品表现值与整体排序有一定影响, 但排序最高的产品始终保持不变, 表明本文所提模型具有较强的鲁棒性.

2.3.2 似然控制参数敏感度分析

为检验似然凹凸程度控制参数 λ 对模型推断与最终排序结论的影响, 在 λ 取值为 $\{1, 3, 5, 7, 10\}$ 下分别运行 4 条马尔科夫链, 并计算偏差信息准则值用于比较拟合优度与有效复杂度的权衡. 结果显示, $\lambda = 5$ 时 4 条链的偏差信息准则值约为 3.96-4.03, 链间波动小, 表明模型在该设定下具有稳定的后验拟合; 相比之下, $\lambda = 10$ 虽呈现更低的平均偏差信息准则值, 但链间波动显著增大, 这说明在偏好硬约束的条件下, 推断结果更易受到边界效应影响, 稳健性不足.

进一步计算不同 λ 取值下产品的 RAI 值分布和平均权重下的综合评价排序. 结果表明, λ 的不同取值下排序结果一致: 前 8 种产品 ($a_{10}, a_1, a_{17}, a_2, a_{12}, a_4, a_{14}, a_{15}$) 的排序在所有设定下相同, 其余产品的排名基本稳定, 仅产品 a_8 与 a_{11} 在第 9 和第 10 名位置出现相邻互换, 属于临界产品之间的微小差

距所致, 不影响总体结论. 综合偏差信息准则值的拟合稳定性表现与排序结果的鲁棒性, 选择 $\lambda = 5$ 是合理的.

2.4 对比分析

为验证所提方法的有效性, 将本文所提方法与随机有序回归 (Stochastic Ordinal Regression, SOR)^[30] 方法在表 5 所示的数据集^[31] 上进行对比.

表5 对比数据集的相关信息

数据集名称	方案数量	属性数量	成对比较方案数量
Thierry's choice (TC)	14	5	3(3)
Industry competitiveness (IC)	31	6	7(7)
Student selection (SS)	76	6	19(19)
Couple's embryos (CE)	51	7	12(12)
Research units (RU)	93	4	23(23)
EIU best cities (EBC)	70	7	17(17)
Market potential index (MPI)	86	8	21(21)
Guardian UK universities (GUU)	118	8	29(29)
Happy planet index (HPI)	151	3	37(37)

为比较两个方法的表现, 通过 Ghaderi 和 Kadziński^[32] 提出的方法构造“真实”偏好模型 $U^{true}(a_i) = \sum_{j=1}^m u_j^{true}(g_j(a_i))$, 该模型假设能反应决策者真实偏好, 再根据该模型得到的方案表现数据构造成对偏好信息. 该方法的步骤如下: 首先, 基于无任何先验信息的狄利克雷分布随机生成一组权重向量 $w = (w_1, w_2, \dots, w_m)$, 保证权重都大于 0 且和为 1. 随后, 定义边际值函数 $u_j^{true}(g_j(a_i)) = w_j(1 - e^{\varpi_j \times g_j(a_i)}) / (1 - e^{\varpi_j})$ 来模拟属性的边际值, 其中, ϖ_j 是确定 u_j^{true} 曲率的参数, 其取值从区间

[-10,10]中随机生成,该参数用于反应决策者的风险偏好(大于0)与风险厌恶态度(小于0).根据定义好的偏好模型,基于成对比较方案数量生成确定型与不确定型偏好信息用作模型的输入(方案数量的1/4为确定型偏好,1/4为不确定型偏好,如表5所示).对于不确定型偏好信息,其概率随机生成.

构造好偏好信息之后,定义三个指标来衡量偏好分解模型在表5中数据集的表现.第一个指标是真实最优方案接受性指数 $AIO = RAI(a^*, 1)$,其中, a^* 表示通过真实价值函数计算得到的排名首位的方案.该指标用于量化“基于抽样价值函数确定的最优方案”与“真实价值函数计算的最优方案”一致的概率. AIO 值域为 [0,1],数值越高表明方法在最优方案识别上的可靠性越强.第二个指标是真实排名

平均支持指数 $ASR = \sum_{i=1}^n RAI(a_i, rank^{true}(a_i)) / n$,其中, $rank^{true}(a_i)$ 表示方案 a_i 在真实价值函数下的排名位置.该指标通过计算所有方案在其真实价值函数得到排名位置上获得的平均接受度,评估偏好分解模型在完整排序重构中的一致性水平.当 ASR 趋近于 1 时,表明抽样价值函数产生的排序与真实排序高度一致.第三个指数为真实成对比较平均支持指数 $ASP = 2 \sum_{i=1}^m \sum_{k=1 \setminus i}^m POI(a_i, a_k) \cdot I(U^{true}(a_i) \geq U^{true}(a_j)) / n(n-1)$,其中,成对比较支持度 $POI(a_i, a_k)$ 计算公式为 $POI(a_i, a_k) = |S_{U(a_i) \geq U(a_j)}| / N$, $|S_{U(a_i) \geq U(a_j)}|$ 是满足 $U(a_i) \geq U(a_j)$ 条件的价值函数的集合.当 $U^{true}(a_i) \geq U^{true}(a_j)$ 时, $I(U^{true}(a_i) \geq U^{true}(a_j)) = 1$;否则, $I(U^{true}(a_i) \geq U^{true}(a_j)) = 0$. ASP 指标通过统计所有方案对在成对比较中与真实偏好关系一致的比例,反映方法在局部偏好关系保持上的有效性.

根据定义的三种指数,两种方法在 9 个数据集上的表现如表 6 所示.根据表 6 数据与 Wilcoxon 符号秩检验的结果可得,本文提出的贝叶斯偏好分解方法均相较于 SOR 方法在 AIO、ASR 和 ASP 三个指标上均显示出统计显著的性能优势.在 AIO 指标上,贝叶斯偏好分解方法在多数数据集(如 TC、IC、SS 等)上的得分略高于 SOR 方法,整体均值(AVG)也从 0.2324 提升至 0.2480,且 p 值为 0.0039($p < 0.01$),说明差异具有高度统计显著性.尽管部分数据集中贝叶斯偏好分解方法在 ASR 与 ASP 两个指标上的提升幅度相对较小,但整体表现仍优于 SOR 方法. Wilcoxon 检验的 p 值均为 0.0273($p < 0.05$),表明贝叶斯偏好分解方法在这两个指标上具有稳定优势.贝叶斯偏好分解方法在这三个指标上的优势验证了

其有效性.

表6 偏好分解算法对比结果

数据集	AIO		ASR		ASP	
	SOR	BPD	SOR	BPD	SOR	BPD
TC	0.2640	0.2850	0.0994	0.0909	0.6533	0.6686
IC	0.1670	0.1840	0.2087	0.2112	0.9138	0.9145
SS	0.1552	0.1667	0.0422	0.0789	0.7262	0.8751
CE	0.0893	0.0990	0.0299	0.0366	0.7491	0.7570
RU	0.3012	0.3323	0.4411	0.4624	0.9128	0.9323
EBC	0.1152	0.1250	0.0416	0.0522	0.7770	0.8233
MPI	0.5545	0.5888	0.0571	0.0581	0.8505	0.8321
GUU	0.0799	0.0801	0.0271	0.0513	0.8188	0.8595
HPI	0.3651	0.3714	0.2415	0.2564	0.9560	0.9807
AVG	0.2324	0.2480	0.1321	0.1442	0.8175	0.8492
Wilcoxon	$p=0.0039 < 0.05$		$p=0.0273 < 0.05$		$p=0.0273 < 0.05$	

注: BPD-贝叶斯偏好分解方法.

3 模型创新与管理启示

相较于传统排序模型(如 TODIM^[11]、MULTIMOORA^[12]、考虑用户评论情感倾向相似度的协同过滤算法^[13]、融合文本评论情绪和评分矩阵的深度学习模型^[14]),本文提出的贝叶斯偏好分解方法的创新性体现在以下方面:

(1) 贝叶斯偏好分解方法在统一的概率框架中贯通多源评价证据、偏好约束与排序输出.评论端的情感证据以概率形式进入偏好表示,排序端不再仅学习单一打分函数,而是学习可解释的准则权重与价值函数参数,并通过后验推断实现从证据到排序的端到端不确定性传播.

(2) 贝叶斯偏好分解方法显式刻画偏好信息的可靠性差异,使不同强度的证据对学习过程产生不同约束力度.其他模型通常将成对样本视为同质约束,而贝叶斯偏好分解方法通过概率化偏好与似然结构将证据强弱内生地体现在后验分布中,从而提升排序稳健性与可校准性.

(3) 贝叶斯偏好分解方法输出的不仅是点估计排序,还包括排序分布及其不确定性度量,可支持置信度排序与解释生成.传统排序模型通常只输出确定性排名或分数,难以回答该排名在偏好噪声下是否稳定.本文提供了一种可解释且能传播不确定性的偏好分解式排序理论框架,为评论驱动的排序学习提供了从证据可靠性到排序稳健性的机制.

结合案例结果发现,“功能”属性权重在总体效用中占主导地位,表明用户更倾向于以核心性能与关键功能作为排序决策的首要依据.这一发现的管理价值不止于解释排名形成机制,更在于为企业提供一条可复用的落地路径,可概括为“诊断-分群-执

行”三步闭环. 第一步是诊断, 即将偏好分解输出转化为改进优先级: 利用准则权重识别对总体效用贡献最大的维度, 确定资源投入的核心; 进一步结合分段价值函数的边际增益定位最有效的改进区间, 例如, 当“功能”价值函数在中低水平区间斜率更大时, 说明补齐基础能力短板比追求极限性能更能显著提升总体满意度, 从而避免在低边际区间投入过多成本. 对“价格”“续航”“服务”等非主导准则, 同样可通过价值函数形态判断其提升策略: 若呈现阈值特征, 则优先推动跨越关键阈值的改进; 若边际收益平缓, 则更适合以成本控制或组合配置来优化而非单准则堆叠. 第二步是分群, 即利用个体或群体层后验分布识别高潜力用户的隐性需求结构: 对于“功能”权重高且不确定性低的群体, 可视为稳定的性能导向用户, 重点在于以功能升级和性能验证提升复购与口碑; 对于“功能”权重高但不确定性较大的群体, 说明其偏好仍处于摇摆或信息不足状态, 更适合用对比解释、场景化评测与决策辅助内容降低认知成本, 以提高转化效率; 对于“功能”权重不占优但在价格敏感或服务敏感维度上呈现高边际增益的群体, 则可定义为差异化驱动用户, 适合用套餐策略、服务承诺或保障机制来提升吸引力. 第三步是执行, 即将偏好结构直接映射为差异化营销策略: 当“功能”主导时, 沟通内容应由抽象卖点转向可验证证据, 突出关键指标、场景表现与同类对比结论; 当价格维度呈现明显阈值时, 策略应聚焦于价格跨越阈值后的可感知收益, 如性价比提升与总拥有成本下降; 当“服务”维度的边际收益集中在特定区间时, 优先强化该区间对应的服务触点, 例如售后响应时效、退换便利性或增值保障, 从而形成可执行的服务改进清单.

总体而言, 本模型提供的权重与分段价值函数不仅解释了排名结果, 更能够支持从关键短板识别、隐性需求分群到差异化沟通执行的决策闭环, 从而提升决策的精准性与响应速度, 减少仅依赖总体评分或黑箱排序模型带来的试错成本.

4 结论

本文提出了基于预训练模型的文本挖掘方法及考虑不确定偏好信息的贝叶斯偏好分解方法用于基于用户生成内容的个性化产品排序推荐, 并通过 JD.com 上同类型医疗手环的用户生成内容作为案例进行了验证. 首先, 对提取的在线评论信息进行文本评论预处理, 利用基于预训练的中文文本向量表示大模型的 BERTopic 框架提取评论中的用户意见词并聚类. 基于 LoRA 框架, 在标注的评论语料上对 Chinese-RoBERTa 模型进行微调, 分析未标注语料的情感等级. 对比分析表明, 提出的文本情感分类方

法在准确率、召回率和 F1 值上优于 LoRA-BERT、双向长短期记忆神经网络、支持向量机、朴素贝叶斯方法和 SnowNLP 这五种方法, 在计算时间上优于全微调的 Chinese-RoBERTa-wwm-ext. 其次, 通过与用户进行交互, 获取用户的同类型产品的准则偏好与不确定的产品偏好, 构建贝叶斯偏好分解模型分解用户偏好信息, 求解出产品排名的 RAI 值为用户提供个性化排序推荐. 通过不同准则偏好场景下的对比分析实验, 验证了所提贝叶斯偏好分解方法的有效性.

本研究中准则的选择未能覆盖产品的所有方面, 评价指标的制定还需要更系统的方法. 本研究在效用建模层面采用了准则独立的加性价值函数, 该设定有助于保持模型结构清晰与推断可解释性. 然而, 不同准则可能存在交互关系(如高功能往往伴随更高价格), 这导致加性假设可能无法充分刻画准则间的真实权衡. 未来研究可在贝叶斯偏好分解框架的基础上引入交互项(如 Choquet 积分)评估准则交互建模带来的增益.

参考文献 (References)

- [1] Timoshenko A, Hauser J R. Identifying customer needs from user-generated content[J]. *Marketing Science*, 2019, 38(1): 1-20.
- [2] 王安宁, 张强, 彭张林, 等. 在线评论的行为影响与价值应用研究综述[J]. *中国管理科学*, 2021, 29(12): 191-202.
(Wang A N, Zhang Q, Peng Z L. A review of behavioral influence and value application for online reviews[J]. *Chinese Journal of Management Science*, 2021, 29(12): 191-202.)
- [3] 蒲中敏, 张晨曦, 徐泽水. 基于在线评论的消费者偏好挖掘研究综述[J]. *中国管理科学*, 2025, 33(1): 209-220.
(Pu Z M, Zhang C X, Xu Z S. Review of consumer preference mining based on online reviews[J]. *Chinese Journal of Management Science*, 2025, 33(1): 209-220.)
- [4] Pu Z M, Xu Z S, Zhang C X, et al. An online review-driven two-stage hotel recommendation model considering customers' risk attitudes and personalized preferences[J]. *Omega*, 2025, 131: 103197.
- [5] Ko D G, Mai F, Shan Z, et al. Operational efficiency and patient-centered health care: A view from online physician reviews[J]. *Journal of Operations Management*, 2019, 65(4): 353-379.
- [6] Wu P, Tang T J, Zhou L G, et al. A decision-support model through online reviews: Consumer preference analysis and product ranking[J]. *Information Processing & Management*, 2024, 61(4): 103728.
- [7] Zhang H T, Kassim A M, Samsudin N H, et al. A hybrid deep learning framework for hotel rating systems: Integrating Word2Vec, TF-IDF, and Bi-LSTM with attention mechanism[J]. *IEEE Transactions on Computational Social Systems*, 2025, 12(5): 2371-2384.

- [8] 彭娟娟, 凌初阳, 隆清琦. 基于云模型的在线协诊三边匹配决策方法 [J]. 控制与决策, DOI: [10.13195/j.kzyjc.2025.0669](https://doi.org/10.13195/j.kzyjc.2025.0669). (Peng J J, Ling Q Y, Long Q Q. Online collaborative diagnosis three-side matching decision-making method based on cloud model[J]. Control and Decision, DOI: [10.13195/j.kzyjc.2025.0669](https://doi.org/10.13195/j.kzyjc.2025.0669).)
- [9] 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: 102784.
- [10] 国显达, 那日萨, 崔少泽. 基于 CNN-BiLSTM 的消费者网络评论情感分析[J]. *系统工程理论与实践*, 2020, 40(3): 653-663. (Guo X D, Na R S, Cui S Z. Consumer reviews sentiment analysis based on CNN-BiLSTM[J]. *Systems Engineering — Theory & Practice*, 2020, 40(3): 653-663.)
- [11] Qin J D, Zeng M Z, Wei X, et al. Ranking products through online reviews: A novel data-driven method based on interval type-2 fuzzy sets and sentiment analysis[J]. *Journal of the Operational Research Society*, 2024, 75(5): 860-873.
- [12] Chen Z Y, Xiao F, Wang Y T, et al. Online review analysis-based multi-criteria decision-making for evaluating patient satisfaction: A case study of the haodf website[J]. *Journal of the Operational Research Society*, 2024, 75(5): 841-859.
- [13] 王伟, 王洪伟, 孟园. 协同过滤推荐算法研究: 考虑在线评论情感倾向[J]. *系统工程理论与实践*, 2014, 34(12): 3238-3249. (Wang W, Wang H W, Meng Y. The collaborative filtering recommendation based on sentiment analysis of online reviews[J]. *Systems Engineering — Theory & Practice*, 2014, 34(12): 3238-3249.)
- [14] Cai Y, Ke W M, Cui E, et al. A deep recommendation model of cross-grained sentiments of user reviews and ratings[J]. *Information Processing & Management*, 2022, 59(2): 102842.
- [15] Lee H C, Rim H C, Lee D G. Learning to rank products based on online product reviews using a hierarchical deep neural network[J]. *Electronic Commerce Research and Applications*, 2019, 36: 100874.
- [16] Wu X L, Liao H C. Value-driven preference disaggregation analysis for uncertain preference information[J]. *Omega*, 2023, 115: 102793.
- [17] Ru Z C, Liu J P, Kadziński M, et al. Bayesian ordinal regression for multiple criteria choice and ranking[J]. *European Journal of Operational Research*, 2022, 299(2): 600-620.
- [18] Yet B, Tuncer Şakar C. Estimating criteria weight distributions in multiple criteria decision making: A Bayesian approach[J]. *Annals of Operations Research*, 2020, 293(2): 495-519.
- [19] Grootendorst M. BERTopic: Neural topic modeling with a class-based TF-IDF procedure[J]. 2022, arXiv: 2203.05794.
- [20] Hu E J, Shen Y, Wallis P, et al. LoRA: Low-rank adaptation of large language models[J]. 2021, arXiv: 2106.09685.
- [21] Cui Y M, Che W X, Liu T, et al. Pre-training with whole word masking for Chinese BERT[J]. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2021, 29: 3504-3514.
- [22] Reimers N, Gurevych I. Sentence-BERT: Sentence embeddings using Siamese BERT-networks[C]. Proceedings of the Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. Hong Kong, 2019: 3980-3990.
- [23] Pang Q, Wang H, Xu Z S. Probabilistic linguistic term sets in multi-attribute group decision making[J]. *Information Sciences*, 2016, 369: 128-143.
- [24] Wu X L, Liao H C. A consensus-based probabilistic linguistic gained and lost dominance score method[J]. *European Journal of Operational Research*, 2019, 272(3): 1017-1027.
- [25] Figueira J, Greco S, Ehrogett M. Multiple criteria decision analysis: State of the art surveys[M]. New York: Springer New York, 2005.
- [26] Liu J P, Kadziński M, Liao X W, et al. Data-driven preference learning methods for value-driven multiple criteria sorting with interacting criteria[J]. *INFORMS Journal on Computing*, 2021, 33(2): 586-606.
- [27] Murphy K P. Machine learning: A probabilistic perspective[M]. Cambridge: MIT Press, 2012.
- [28] Rahat A M, Kahir A, Masum A K M. Comparison of naive Bayes and SVM algorithm based on sentiment analysis using review dataset[C]. Proceedings of the 8th International Conference System Modeling and Advancement in Research Trends. Moradabad, 2019: 266-270.
- [29] Gelman A, Hwang J, Vehtari A. Understanding predictive information criteria for Bayesian models[J]. *Statistics and Computing*, 2014, 24(6): 997-1016.
- [30] Kadziński M, Tervonen T. Robust multi-criteria ranking with additive value models and holistic pair-wise preference statements[J]. *European Journal of Operational Research*, 2013, 228(1): 169-180.
- [31] Ciomek K, Kadziński M, Tervonen T. Heuristics for selecting pair-wise elicitation questions in multiple criteria choice problems[J]. *European Journal of Operational Research*, 2017, 262(2): 693-707.
- [32] Ghaderi M, Kadziński M. Incorporating uncovered structural patterns in value functions construction[J]. *Omega*, 2021, 99: 102203.

作者简介

刘凡 (1995-), 男, 副教授, 博士, 主要研究方向为偏好学习、在线平台, E-mail: liufan951019@163.com;

廖虎昌 (1989-), 男, 研究员, 博士, 博士生导师, 主要研究方向为智能决策、服务管理, E-mail: liaohuchang@163.com.