

# 基于多特征融合的智能客服用户评论行为预测及可解释性分析

张志霞, 许慧琳\*

西安建筑科技大学管理学院, 陕西 西安

收稿日期: 2026年3月11日; 录用日期: 2026年3月25日; 发布日期: 2026年5月28日

## 摘要

智能客服作为用户与平台交互的核心渠道, 仍面临服务瓶颈与用户态度两极分化的问题, 致使对用户行为预测变得至关重要。基于感知价值理论, 本文借助BERTopic模型从评论数据中识别感知价值维度; 并采用集成自注意力机制的双向长短期记忆(BiLSTM)模型识别感知价值评分与情感倾向。结合用户基本特征、感知价值特征与情感特征, 通过常春藤算法优化BP神经网络(IVY-BP)对用户评论行为进行预测。结果表明, 用户情感呈现显著的两极分化趋势; IVY-BP模型在准确率与F1分数上均优于PSO-BP与GA-BP模型, 验证了多特征融合相较于单一特征的优越性; SHAP可解释分析显示, 影响力、认证类型、功能价值与社会价值是评论行为的关键驱动因素。

## 关键词

智能客服, 评论行为预测, 感知价值, 多特征融合, 常春藤算法

# Intelligent Customer Service User Comment Behavior Prediction and Explainability Analysis Based on Multi-Feature Fusion

Zhixia Zhang, Huilin Xu\*

School of Management, Xi'an University of Architecture and Technology, Xi'an Shaanxi

Received: March 11, 2026; accepted: March 25, 2026; published: May 28, 2026

## Abstract

As the core channel for user-platform interaction, intelligent customer service systems still face service

\*通讯作者。

文章引用: 张志霞, 许慧琳. 基于多特征融合的智能客服用户评论行为预测及可解释性分析[J]. 电子商务评论, 2026, 15(5): 721-731. DOI: 10.12677/ecl.2026.155570

**bottlenecks and user attitude polarization, making user behavior prediction critically important. Based on perceived value theory, this study utilizes the BERTopic model to identify perceived value dimensions from review data, and employs a bidirectional long short-term memory (BiLSTM) model with an integrated self-attention mechanism to analyze perceived value scores and emotional tendencies. By integrating user basic characteristics, perceived value features, and emotional traits, we optimize the backpropagation neural network (IVY-BP) using the Ivy algorithm to predict user review behaviors. Results demonstrate significant polarization in user emotions; the IVY-BP model outperforms PSO-BP and GA-BP models in both accuracy and F1 score, validating the superiority of multi-feature fusion over single-feature approaches. SHAP explanatory analysis reveals that influence level, certification type, functional value, and social value serve as key drivers of review behavior.**

## Keywords

**Intelligent Customer Service, Comment Behavior Prediction, Perceived Value, Multi-Feature Fusion, Ivy Algorithm**

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

人工智能(AI)与机器学习的持续发展,推动了 AI 驱动对话系统在在线客服领域的广泛应用[1]。这些虚拟客服代理取代人工客服,提供全天候支持,既能减轻人力成本压力,又能降低企业开支,同时提升客户服务效率[2]。

然而,技术快速渗透的背后,当前智能客服系统仍面临关键能力瓶颈,在自然语言理解的精准度、情感需求的适应性以及上下文对话的连贯性上,与 ChatGPT 等先进大语言模型存在明显差距。这些局限性直接导致服务中断、问题解决不彻底等失败场景频发,进而引发客户不满情绪蔓延与负面口碑传播,最终对企业品牌竞争力造成损害[3]。而这一矛盾在微博等社交媒体平台上被急剧放大,此类平台能为公众提供表达观点意见的渠道[4]。用户从单纯的信息接收者转变为内容生产者与传播者,其即时评论行为直接反映了对智能客服的真实态度,还极易受到其他用户高涨情绪的传染,从而不自觉地调整自己的行为轨迹[5],甚至因信息过载与算法推荐形成“回音室效应”。因此,用户评论是网络观点情感表达的重要方式,其预测研究对解决智能客服痛点至关重要,可助企业识别风险、优化系统以及提升满意度,连接智能客服与用户体验,促进行业发展。

在用户评论行为预测的研究中,学者们主要从三方面对此进行探究。在行为预测方面,现有研究过度依赖用户关系网络建模,只考虑了事件属性、用户影响力等变量对评论行为的动态影响,丁晟春等以新浪微博中两类不同的突发事件为例,收集其中做出交互行为的用户数据,在理论研究与统计分析的基础上,将做出点赞、评论、转发 3 种行为的用户所具备的有效属性作为特征指标[6]。然而,行为预测需要考虑多个因素,融合多特征的行为预测模型构建是必要的,而当前的行为预测研究往往仅关注部分因素。沈旺等提出一种融合网络事件特征的 DRSN-CW-LSTM 混合网络架构用户在线评论行为预测模型,该模型综合考量并提取不同用户特征与舆情事件特征,融合深度残差收缩网络与长短时记忆网络的混合网络模型,将软阈值化作为非线性层引入深度残差收缩网络结构,提升用户在线评论行为预测的准确性[7]。在影响因素层面,学者们从用户特质[8]、内容框架[9]等视角解析行为成因,陈璟浩等人[10]发现,文旅短视频中的体验框架可通过激发喜爱情绪促进评论,而不同叙事方式会调节该情绪路径。也有借助

理论构建模型[11], 分析用户需求[12], 或针对用户评论行为的关键因素[13]和从众信息评论这种特定行为进行分析。相关研究也重点关注了用户作为信息生产者的感知和行为, 探索他们在使用技术过程中的可信度感知、效用感知等[14], 以及这些感知对用户采纳和持续使用等行为的影响[15]。因此, 针对在消费过程中用户对智能客服的具体感知以及评论、点赞等交互行为仍需进一步探索。

综上, 基于上述研究的局限性, 本文结合感知价值理论, 解释影响用户评论的因素; 在行为预测建模上, 既有模型过度依赖静态数据, 未能有效融合智能客服场景中动态、多源的交互特征, 导致对评论行为的解释和预测精度不足, 通过构建多特征融合模型预测用户评论行为, 结合 SHAP 进行可解释性分析, 揭示感知价值不同维度对评论行为的影响机制。

## 2. 数据来源与方法

### 2.1. 数据收集与预处理

微博平台作为代表性的社交媒体平台之一, 其核心特征在于同时覆盖用户关注网络、互动行为记录以及大量文本内容[16]。平台拥有庞大用户群体、高活跃度和广泛覆盖, 能较好地反映公众对智能客服的认知态度, 因此本研究选取微博作为数据来源。采用 `weibo-scraper` 库和 `Selenium` 工具爬取公开评论数据, 避免反爬机制, 爬取用户层、内容层、行为层信息, 为特征提取提供数据支撑; 以“智能客服”等为核心检索词, 时间跨度为 2023 年 1 月 1 日至 2025 年 1 月 1 日, 初始获得 15,821 条数据。通过用户 ID、时间戳和内容比对删除重复记录, 排除无核心关键词的文本, 并剔除短文本或高特殊符号文本, 最终获得 8976 条。

### 2.2. 感知价值维度识别与情感分析

BERTopic 模型使用强大的上下文嵌入和基于类的术语频率倒置文档频率(c-TF-IDF)算法来为每篇文章提取不同的主题和相应的概率[17]。本研究采用 BERTopic 主题建模模型提取感知价值相关的语义主题, 具体利用 `Chinese-BERT-wwm` 生成文本向量, 再经 UMAP 降维和 HDBSCAN 聚类构建主题结构。参数经多组实验调试, 确保主题可分性并避免小簇[18]。模型识别出主题, 剔除低概率文档作为噪声, 基于 c-TF-IDF 提取主题词项, 并与感知价值维度语义对应, 结合词向量相似度和关键词重叠, 将主题归纳为感知价值维度。此外, 采用自注意力机制的双向长短期记忆(BiLSTM)进行五级情感分类(1 = 非常负面、5 = 非常正面), 作为感知价值打分基础。但由于分类存在类别不平衡和模糊性问题, 引入一对一(OVO)策略, 将 5 类拆分为 10 组, 训练 10 个子分类器, 通过概率投票确定情感等级。结合文本结构与感知价值维度, 通过三名研究者进行人工标注, 分割文本为句子, 制定参考文档, 随机抽取 200 句试标, 计算 Kappa 系数, 发现一致性良好, 校准标准后同步打分情感与感知价值, 形成标注数据集。

### 2.3. 特征工程与融合

#### 2.3.1. 用户的基本特征

用户的基本特征是以用户画像及社交影响力为核心, 量化用户固有属性及平台参与行为能力, 为评论行为预测提供用户层面的驱动性线索。结合智能客服评论场景的特殊性, 选取性别、认证类型、活跃度、影响力 4 类核心特征, 其中性别和认证类型分别采用虚拟变量编码; 活跃度选取用户的关注数和微博数, 关注数表示关注上层用户的数量, 微博数表示用户注册以来发微博的次数, 其中计算公式如下:

$$activity = \theta \cdot attention + \gamma \cdot micronlogs \quad (1)$$

式中,  $\theta$  和  $\gamma$  分别是被关注数和发微博数的权重。

影响力选取用户的粉丝数, 粉丝数表示用户被关注的程度, 计算公式如下:

$$influnce = N_{flows} \tag{2}$$

### 2.3.2. 特征选择

本研究基于 BiLSTM 模型进行五级情感分类, 核心为情感倾向得分。因微博数据采集限制, 仅选取点赞、评论、转发为研究对象, 点赞和转发体现单向认同或扩散, 成本低、信息有限; 评论需主动输出文字, 实现双向互动, 信息密度高、交互深。因此, 以用户是否发起评论为核心预测目标, 最后通过多维度分析和文献参考, 提取智能客服用户评论行为的核心关联特征并整理为表 1。

**Table 1.** List of correlation features of user comment behavior in intelligent customer service

**表 1.** 智能客服用户评论行为关联特征表

特征分类	特征名称	指标
用户基本特征	性别	用户注册性别
	认证类型	账号认证类型
	活跃度	累计发布微博数
		用户关注数
用户感知价值因素特征	影响力	粉丝数
	功能价值	功能价值评价价值
	体验价值	体验价值评价价值
	社会价值	社会价值评价价值
用户情感特征	感知风险	感知风险评价价值
	情感倾向	情感倾向得分
预测目标	评论行为	用户是否发起评论(1 = 是, 0 = 否)

### 2.3.3. 特征融合

相关领域的现有研究中大多使用拼接的方式实现多特征融合[19]。在得到评论文本的感知风险、功能价值、体验价值、社会价值、活跃度、影响力和情感特征后, 本文对上述特征进行拼接融合, 从而得到每个信息文本进行模型训练和预测所需要的特征序列, 将其输入 IVY-BP 模型中。

$$Doc_i = [C_i, M_i, V_i, S_i, T_i, D_i] \tag{3}$$

式中,  $i$  表示第  $i(0 \leq i \leq n)$  条评论文本;  $n$  为评论文本数量;  $C_i$  为感知风险;  $M_i$  为感知价值;  $V_i$  为活跃度;  $S_i$  为文本情感分数;  $T_i$  为影响力;  $D_i$  为认证类型。对以上特征进行拼接融合, 形成综合的特征表示  $Doc_i$ , 将其输入 IVY-BP 模型中。

## 2.4. 基于常春藤算法改进的 BP 神经网络模型

### 2.4.1. 算法原理

BP 神经网络用于分类与预测, 但传统 BP 网络存在初始权值敏感和收敛速度慢的局限。本研究引入常春藤算法(IVY)进行全局优化, 其生长蔓延特性可解决初始权值敏感问题[20]。IVY 算法基于常春藤占据空间的方式, 具有优秀全局寻优能力和鲁棒性, 能以非线性方式寻优, 避开局部极小点, 提高网络性能并缩短训练时间, 为 BP 神经网络提供更好的初始化方法。该算法首先创建一组位置随机的常春藤植物种群, 种群中的每个个体代表一个可能的解。个体通过目标函数评估其适应度, 适应度越高(或越低,

由目标函数决定), 表示个体解越优。常春藤算法先利用式(4)在搜索空间内随机产生若干株常春藤植物个体, 在对 BP 神经网络进行优化的过程中, 每株常春藤植物个体位置表示一种超参数。

$$I_i = I_{\min} + rand(1, D) \odot (I_{\max} - I_{\min}) \quad (4)$$

式中,  $I_i$  为常春藤植物个体;  $i \in [1, N_{pop}]$ ;  $N_{pop}$  为个体总数;  $rand(1, D)$  表示随机生成一个  $D$  维的向量; 向量的每个分量在  $[0, 1]$  区间;  $I_{\min}$  和  $I_{\max}$  分别为搜索空间的下界和上界;  $\odot$  表示逐元素积。

假设常春藤生长速度为  $Gv$ , 其生长速度由式(5)给出:

$$\frac{dGv(t)}{dt} = \psi \cdot Gv(t) \cdot \varphi(Gv(t)) \quad (5)$$

式中,  $Gv(t)$  为生长速度;  $\psi$  为生长率常数;  $\varphi$  为修正因子。通过试验和仿真, 得到式(6)可以描述个体的生长速度。在优化 BP 神经网络模型时, 其植物的生长速度可以决定超参数更新的速度。

$$\Delta Gv_i(t+1) = rand^2 \cdot (N(1, D) \odot \Delta Gv_i(t)) \quad (6)$$

式中,  $\Delta Gv_i(t+1)$  和  $\Delta Gv_i(t)$  分别为个体  $i$  在  $t+1$  和  $t$  时刻的生长速度增量;  $rand^2$  是一个概率密度为  $(1/2\sqrt{x})$  的随机变量;  $N(1, D)$  是一个维度为  $D$  的标准高斯分布的随机向量。常春藤种群中的个体更倾向于选取邻近且性能更优的个体作为参考目标, 实现局部深度探索, 位置更新。式(7)与式(8)说明了常春藤植株通过相邻个体朝向光源方向生长的具体机制。在优化过程中, 这种个体模仿强邻居行为向目标区域移动的现象可类比于超参数基于相邻优质配置逐步趋近全局最优解的行为模式。

$$I_i^{new} = I_i + |N(1, D)| \odot (I_{ii} - I_i) + N(1, D) \odot \Delta Gv_i \quad (7)$$

$$\Delta Gv = \begin{cases} I_i \cdot / (I_{\max} - I_{\min}), & Iter = 1 \\ rand^2 \cdot (N(1, D) \odot \Delta Gv_i), & Iter > 1 \end{cases} \quad (8)$$

式中,  $I_i^{new}$  是由  $I_i$  产生的新个体;  $I_{ii}$  是  $I_i$  的最强邻居;  $\Delta Gv_i$  为  $I_i$  的速度; “ $\cdot /$ ” 表示符号前后元素逐个做除法;  $Iter$  为迭代次数。在  $I_i$  借助  $I_{ii}$  最强邻居进行生长后, 此个体通过整合种群中实现个体生长, 式(9)与式(10)详细阐释了这一过程。在过程中, 常春藤植物借助最强个体生长的过程对应于超参数基于现有最佳配置持续迭代优化的过程。

$$I_i^{new} = I_{best} \odot ((rand(1, D)) + N(1, D) \odot \Delta Gv_i) \quad (9)$$

$$\Delta Gv_i^{new} = I_i^{new} \cdot / (I_{\max} - I_{\min}) \quad (10)$$

式中,  $I_{best}$  为整个种群最强个体;  $\Delta Gv_i^{new}$  是新个体  $I_i^{new}$  的新生长速度。IVY 优化 BP 神经网络模型的过程如图 1 所示。

### 2.4.2. 评价指标

分类机器学习模型性能主要通过 AUC 值、准确率(Accuracy)、召回率(Recall)、精确率(Precision)、F1 值等指标进行评价。行为预测的目标是将输入的评论文本进行二分类, 本文将用户进行评论被视为正分类, 未进行评论被视为负类, 将采用的文本分类任务中常用的评价指标, 分别是精确率、准确率、召回率和 F1 值, 对 IVY-BP 神经网络的分类预测结果进行评估。这些指标通常用于评估分类器的性能, 根据具体的应用场景选择相应的指标进行评价, 各指标的计算依赖混淆矩阵的统计结果, 混淆矩阵的定义与分类标签对应关系见表 2, 计算如公式(11)~(14)所示:

**Table 2.** Statistical table of experimental results  
**表 2.** 实验结果统计表

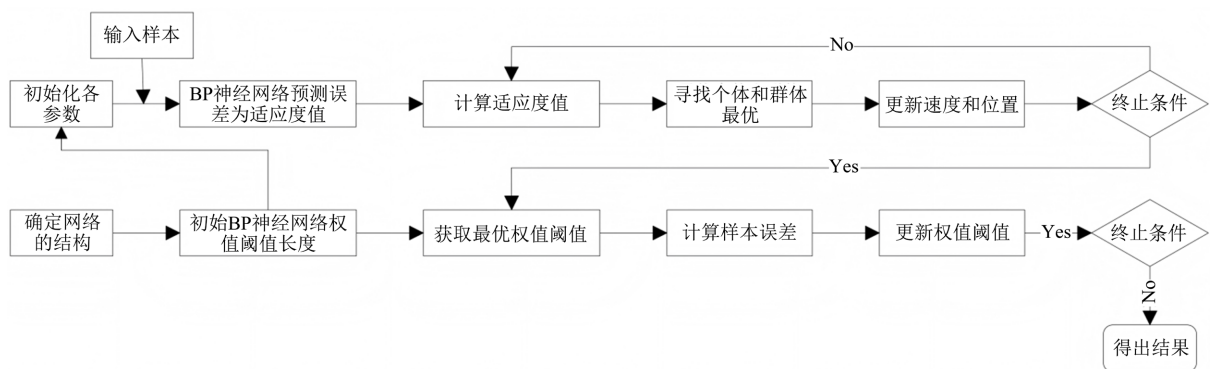
混淆矩阵		模型的预测标签	
		0	1
真实标签	0	TN	FP
	1	FN	TP

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (11)$$

$$Precision = \frac{TP}{TP + FP} \quad (12)$$

$$Recall = \frac{TP}{TP + FN} \quad (13)$$

$$F1 = \frac{2Precision \times Recall}{Precision + Recall} \quad (14)$$



**Figure 1.** Flowchart of the IVY algorithm for optimizing the BP neural network  
**图 1.** IVY 算法优化 BP 神经网络流程

### 3. 实验结果与分析

#### 3.1. 感知价值因素挖掘

为了揭示智能客服评论中的潜在主题，本研究对 BERTopic 主题模型进行了微调，将 UMAP 参数设置为  $n\_neighbors = 5$  和  $min\_dist = 0.2$ 。HDBSCAN 配置的最小簇大小为 100，最终主题形成。通过已识别的主题、代表性关键字以及相应的语义描述，将这些主题随后映射到各维度中，具体结果见表 3。对于感知风险，Topic1 捕获了用户对服务故障的关注，包括延迟响应、低效的投诉处理和访问支持方面的困难。Topic5 强调对人工智能可能替代传统人工客服岗位的担忧，这反映了用户感受到的社会和职业风险。在功能价值方面，Topic0 和 Topic3 代表了对技术有效性和平台可用性的积极评价。这些评价表明，功能性能对用户感知价值有显著贡献。在体验价值方面，Topic2 中太棒了、真不错等词代表用户体验方面的词汇，反映了用户对服务提供商的技术支持的认可。在社会价值方面，Topic4 反映了用户对人工智能更广泛的社会贡献的期望，体现出用户对该技术的社会价值认知。这些映射表明，用户评论不仅反映了即时的满意或不满意，而且反映了对功能、体验、社会和风险相关方面更深层次的认知评估。

**Table 3.** Topics and keywords of customer reviews for intelligent customer service  
**表 3.** 智能客服用户评论主题及其关键词

主题	主题表征(数量)	代表性关键词	主题描述	感知维度
Topic0	服务_平台_技术_用户 (1249)	服务、平台、技术、用户、商家、模型、企业、产品、机器人、客户	技术进步	功能价值
Topic1	驿站_打电话_投诉_服务 (2113)	驿站、打电话、投诉、服务、机器人、转人工、送货上门、语音、解决	客户问题解决	感知风险
Topic2	太棒了_真不错_厉害_好用 (839)	太棒了、真不错、厉害、挺不错、太强大、太快、工作、太牛、太给力、好用	用户体验	体验价值
Topic3	厉害_技术_声音_模型(186)	厉害、技术厉害、技术、声音、模型、神奇	人工智能技术	功能价值
Topic4	期待_领域_技术_模型 (1014)	期待、领域、技术、模型、人类、体验、创新、提升、服务、商业	技术应用展望	社会价值
Topic5	模型_取代_技术_工作 (429)	模型、取代、技术、工作、高效、提升、语言、便捷、简单	工作替代影响	感知风险


### 3.2. 情感分析

本研究采用自注意力机制的 BiLSTM 模型进行情绪分类, 根据表 4 中的训练集结果, 可以发现该模型在积极情感和消极情感上取得了较高的性能, 准确率分别为 85%和 83%, F1 分数为 0.88; 中性情感具有较低的性能, 其准确率为 0.17, 召回率为 0.11, 这是因为中性情感在语言表达上多为客观陈述, 缺乏强烈情感词汇, 特征区分度较弱, 导致模型判断准确率较低。

**Table 4.** Confusion matrix of training set models  
**表 4.** 训练集模型的混淆矩阵

情感极性	准确率	召回率	F1 分数	样本数
积极	0.85	0.88	0.85	531
中性	0.17	0.11	0.13	46
消极	0.83	0.88	0.85	589
宏平均	0.62	0.60	0.61	1166
带权重平均	0.81	0.82	0.82	1166

本研究进一步利用训练好的模型对智能客服用户评论进行情感倾向预测, 得到三类情感倾向结果。从图 2 的结果可以发现智能客服用户评论情感倾向中消极评论超半数, 中性仅 3.5%, 这说明超半数用户有不满, 近半数认可其服务。



**Figure 2.** Emotional analysis chart  
**图 2.** 情感分析图

### 3.3. 感知价值数据标注与分类性能评估

利用 BERTopic 主题建模对评论进行主题抽取, 得到用户在意的感知价值, 在确定感知因素框架后, 根据数据标注方法进行抽样与人工打分。最终, 共获得 8976 条感知因素打分标注数据, 为提高感知价值维度的分类性能, 本研究在消融实验中以自注意力机制的双向长短期记忆网络(BiLSTM)的组合模型作为基线。根据表 5 的数据可以发现, 感知风险维度的第 2 类与第 4 类以及第 1 类与第 2 类表现尤为突出。该结果表明, 自注意力机制能有效捕捉关键语义特征及其边界信息。在功能价值维度中, 跨类别分类准确率达 0.9954~0.9967, 证实 BiLSTM 的长时依赖特性有助于解析具象化词汇的语义表征。体验价值维度的分类准确率区间为 0.79~0.95。社会价值维度中第 2 类子项的准确率达 0.9254, 验证了行为建模的有效性; 其 0.79~0.9254 的波动范围优于同类研究基准, 证明模型在语义处理层面具有显著鲁棒性。

**Table 5.** Accuracy (%) of OVO sub-classifier on validation set  
**表 5.** OVO 子分类器在验证集的准确率(%)

感知因素	测试类别	2	3	4	5
感知风险	1	0.9888	0.8472	0.9898	0.8124
	2		0.9816	0.9062	0.9931
	3			0.8375	0.9948
	4				0.9948
功能价值	1	0.82	0.9967	0.9935	0.9954
	2		0.983	0.9612	0.9766
	3			0.9026	0.7036
	4				0.8808
体验价值	1	0.9026	0.9265	0.9551	0.8987
	2		0.7952	0.7939	0.8693
	3			0.822	0.8065
	4				0.8512
社会价值	1	0.79	0.9026	0.8363	0.8681
	2		0.9254	0.8537	0.7985
	3			0.8155	0.9181
	4				0.8974

### 3.4. 模型对比与多特征融合分析

#### 3.4.1. 模型对比

基于前文所构建的评论行为相关特征体系, 聚焦评论行为预测任务, 本文优化了 IVY-BP 的主要参数, 种群数量  $N = 300$ , 最大迭代次数 800 次, 搜索范围设为  $[-4.0, 4.0]$ , 决策阈值取 0.45。针对数据类别不平衡, 采用 F1 和召回率综合评价模型效果。在对比实验中, 首先对 Adam-BP 模型进行了优化, 其 5 折交叉验证的召回率与精确率较低, 模型将所有样本均误判为多数类(类别 0), 这说明传统的梯度下降优化器极易陷入局部最优或产生预测偏向, 而引入常春藤算法(IVY)进行全局寻优, 能够跨越非凸损失函数的平坦区, 为网络提供更具鲁棒性的初始参数。因此, 本研究将 IVY 优化的 BP 神经网络与 PSO 和 GA

优化的 BP 神经网络模型进行了比较, 通过表 6 的数据结果对比分析发现 IVY-BP 的准确率、精确率以及召回率都优于 PSO-BP 和 GA-BP。

**Table 6.** Optimization of BP neural network by three algorithms  
**表 6.** 3 种算法优化 BP 神经网络的效果

算法	准确率/%	精确率/%	召回率	F1 值
IVY-BP	81.49%	86.60%	80.86%	79.39%
PSO-BP	78.83%	82.19%	72.11%	76.80%
GA-BP	81.45%	85.99%	73.93%	79.49%

### 3.4.2. 多特征融合分析

为评估不同特征类型对评论行为预测的影响, 本研究将 9 个特征划分为用户的基本特征和感知价值特征、感知风险特征、情感特征, 用户的基本特征包括活跃度、影响力、验证类型以及性别, 见表 7。

**Table 7.** Recognition performance of basic features combined with other features  
**表 7.** 基本特征与其他特征组合的识别效果

特征维度	准确率	精确率	召回率	F1 值
基本特征	73.73%	98.94%	36.91%	53.76%
基本特征 + 情感特征	75.66%	90.71%	45.90%	60.91%
基本特征 + 感知风险特征	82.11%	96.50%	65.62%	78.10%
基本特征 + 感知价值特征	80.33%	87.17%	69.87%	77.56%
基本特征 + 情感特征 + 感知风险特征	82.00%	95.2%	66.10%	78.17%
基本特征 + 情感特征 + 感知价值特征	81.10%	85.71%	73.37%	79.06%
基本特征 + 情感特征 + 感知风险特征 + 感知价值特征	81.49%	86.60%	80.86%	79.39%

实验结果表明, 基础特征组合的模型虽然精确率达到 98.94%, 但召回率仅为 36.91%, F1 值 53.76%, 显示出静态特征在识别正类样本方面的局限性。通过逐步引入情感特征、感知风险和感知价值等动态特征后, 模型性能得到显著提升。其中, 感知价值的加入使召回率提升至 69.87%, F1 值达到 77.56%, 表明该特征能有效捕捉用户的评论行为; 而感知风险的加入则保持了较高的精确率, 说明其在减少误判方面具有优势。情感特征的引入进一步改善了模型性能, 当其与感知价值结合时, F1 值提升至 66.86%, 显示出良好的协同效应。最终, 包含全部 9 个特征的完整模型在所有指标上表现最优, 准确率达到 81.49%, F1 值 79.39%, 精确率 86.60%, 召回率 80.86%, 验证了多特征融合策略的有效性。

### 3.5. 基于 SHAP 的特征重要性分析

为进一步识别影响用户评论行为的关键因素, SHAP 被集成到 IVY-BP 模型的输出层。SHAP 为每个特征分配一个 Shapley 值, 以衡量它们对模型输出的贡献[21]。SHAP 分析结果表明(图 3), 影响力与模型预测结果呈现高度的正向关联, 这反映出拥有更多关注者的用户在社交媒体上通常具备更高的活跃度与表达意愿。然而, 影响力的显著性可能受到用户职业背景等因素的影响, 即这些隐藏变量可能同时作用于用户的影响力与其评论动机。同样地, 功能价值虽然展现出极高的核心贡献度, 但其对评论行为的激励作用可能交织了智能客服实际功能与用户预期之间的差值。




Figure 3. Interpretability analysis  
图 3. 可解释性分析

#### 4. 结论

1) 通过微博平台智能客服评论的实证分析, 借助 BERTopic 主题建模识别出功能价值、体验价值、社会价值与感知风险四个维度, 验证了感知价值理论在智能客服领域的适用性, 其次是情感分析结果表明用户评论呈明显两极分化, 用户既认可智能客服的效率提升, 又对其服务质量表达不满。积极情感聚焦于响应速度和问题解决, 负面情感主要针对响应延迟、语义误解等交互失败场景, 反映出技术复杂性与服务体验之间的矛盾性。

2) 预测模型方面, IVY-BP 模型准确率 81.49%、F1 值 79.39%, 优于 PSO-BP 和 GA-BP, 多特征融合发现 F1 值从单一特征的 53.76% 提升至 79.39%, 显著增强模型预测精度与泛化能力, 表明多维度特征整合对提升预测性能具有重要作用。

3) 通过 SHAP 分析发现影响力是最重要的影响因素, 其中高关注度用户的评论与模型预测结果呈正相关关系, 但是这个影响力的大小受到用户的职业背景、账号长度等的影响, 在一定程度上高影响力的用户具有较强的在社交媒体上活跃的习惯。功能价值是感知价值的核心部分, 它的正向作用说明平台的功能性和易用性与用户的表达意愿有关, 但是也有可能受到用户的期望差异的影响, SHAP 值更多地反映了功能价值对于预测的重要性。社会价值能够促进社区之间的交流沟通, 而感知的风险则会阻碍人们进行评论的动力。

本文也有不足之处, 第一, 本文的数据来自微博, 而微博用户的年龄结构、表达方式以及使用环境等方面都有其独特之处, 与抖音等主流社交媒体存在较大差异, 对于其他平台、其他语言、不同种类的服务型机器人是否适用还需要进行更多的研究分析。第二, 在情感分类中发现中性类别识别较弱, 因中性评论特征边界模糊, 未来研究可将中性样本归为非极性或使用加权损失函数, 以提升模型鲁棒性。第三, 用常春藤优化算法找到最佳的参数集, 所需时间较长, 无法达到快速评论检测所需要的速度以及大量的要求, 所以本文更适合用于辅助决策或者较少频次的场合, 在大规模应用中还是需要进行模型优化、增量学习以及系统优化等研究。

## 基金项目

本文为陕西省自然科学基金一般项目-面上项目(用户对客服机器人算法厌恶的形成机理与治理路径研究)(项目号: 2025JC-YBMS-831)研究成果之一。

## 参考文献

- [1] Juquelier, A., Poncin, I. and Hazée, S. (2025) Empathic Chatbots: A Double-Edged Sword in Customer Experiences. *Journal of Business Research*, **188**, Article 115074. <https://doi.org/10.1016/j.jbusres.2024.115074>
- [2] Polimerou, R. and Spais, G. (2025) Establishing Relationships between Brands and Customers via Strategic Social Media Chatbots for Telecom Goods and Services. *Journal of Marketing Analytics*, **13**, 328-370. <https://doi.org/10.1057/s41270-025-00396-5>
- [3] 裴学亮, 邓辉梅. 基于淘宝直播的电子商务平台直播电商价值共创行为过程研究[J]. 管理学报, 2020, 17(11): 1632-1641+1696.
- [4] Kim, K., Sin, S.J. and Yoo-Lee, E.Y. (2014) Undergraduates' Use of Social Media as Information Sources. *College & Research Libraries*, **75**, 442-457. <https://doi.org/10.5860/crl.75.4.442>
- [5] Liu, Y. and Fan, F. (2023) ChatGPT-AIGC Users Risk Perception Dimension Identification and Management Research: An Exploratory Analysis Based on Grounded Theory. *Information Studies: Theory & Application*, **47**, 1-13.
- [6] 丁晟春, 包舟, 刘笑迎. 突发事件舆情传播中用户交互行为预测研究[J]. 现代情报, 2023, 43(9): 111-123.
- [7] 沈旺, 李欣, 孙珂, 等. 网络舆情事件用户在线评论行为预测研究[J/OL]. 现代情报: 1-18. <https://link.cnki.net/urlid/22.1182.G3.20251013.1053.002>, 2025-11-10.
- [8] Samudro, A., Sumarwan, U., Simanjuntak, M. and Yusuf, E.Z. (2020) Assessing the Effects of Perceived Quality and Perceived Value on Customer Satisfaction. *Management Science Letters*, **10**, 1077-1084. <https://doi.org/10.5267/j.msl.2019.11.001>
- [9] 乐承毅, 孔维伟, 段楠楠. IP 属地化政策对舆情评论的影响研究——基于微博用户属地公开的准自然实验[J]. 图书情报知识, 2024, 41(1): 46-57.
- [10] 陈璟浩, 贾枫. 文旅短视频传播效果的影响因素: 媒体框架、叙事方式与情绪效应[J]. 图书情报工作, 2025, 69(9): 62-77.
- [11] 张帅, 王文韬, 周华任, 等. 基于扎根理论的弹幕视频网站用户使用行为驱动因素研究[J]. 情报理论与实践, 2018, 41(7): 117-122.
- [12] Tong, C. and Zhao, X.Y. (2019) Exploring Users' Motivations and Behaviors on Danmaku Video Sharing Websites: A Content Analysis. *Library Tribune*, **39**, 80-89.
- [13] 冯钰茹, 邓小昭. 弹幕视频网站用户弹幕评论行为的影响因素研究——以 Bilibili 弹幕视频网站为例[J]. 图书情报工作, 2021, 65(17): 110-116.
- [14] 刘晓晴, 邓春林. 舆情卷入风险感知下社交媒体用户非理性行为生成机理研究[J]. 图书情报工作, 2024, 68(7): 123-136.
- [15] Lai, C.Y., Cheung, K.Y., Chan, C.S. and Law, K.K. (2024) Integrating the Adapted UTAUT Model with Moral Obligation, Trust and Perceived Risk to Predict ChatGPT Adoption for Assessment Support: A Survey with Students. *Computers and Education: Artificial Intelligence*, **6**, Article 100246. <https://doi.org/10.1016/j.cacai.2024.100246>
- [16] Sun, G., Wang, S., Zhang, Y., Liu, Y., Gao, J. and Xie, Q. (2023) Behavior Analysis of User Interaction on Online Short Video Platform. *Journal of Computing and Information Technology*, **30**, 51-65. <https://doi.org/10.20532/cit.2022.1005499>
- [17] Raman, R., Pattnaik, D., Hughes, L. and Nedungadi, P. (2024) Unveiling the Dynamics of AI Applications: A Review of Reviews Using Scientometrics and BERTopic Modeling. *Journal of Innovation & Knowledge*, **9**, Article 100517. <https://doi.org/10.1016/j.jik.2024.100517>
- [18] Grootendorst, M. (2022) BERTopic: Neural Topic Modeling with a Class-Based TF-IDF Procedure. arXiv: 2203.05794.
- [19] 陈燕方, 周晓英. 基于文本特征融合的衍生性网络健康谣言识别模型研究[J]. 图书情报工作, 2023, 67(14): 73-84.
- [20] Ghasemi, M., Zare, M., Trojovský, P., Rao, R.V., Trojovská, E. and Kandasamy, V. (2024) Optimization Based on the Smart Behavior of Plants with Its Engineering Applications: Ivy Algorithm. *Knowledge-Based Systems*, **295**, Article 111850. <https://doi.org/10.1016/j.knosys.2024.111850>
- [21] Bifarin, O.O. (2023) Interpretable Machine Learning with Tree-Based Shapley Additive Explanations: Application to Metabolomics Datasets for Binary Classification. *PLOS ONE*, **18**, e0284315. <https://doi.org/10.1371/journal.pone.0284315>