

doi: 10.3969/j.issn.0490-6756.2018.04.011

# 基于状态转移的奖励值音乐推荐研究

谭斌<sup>1</sup>, 孙界平<sup>2</sup>, 瑶生根<sup>2</sup>, 李微<sup>1</sup>

(1. 四川大学锦江学院, 彭山 620860; 2. 四川大学计算机学院, 成都 610065)

**摘要:** 听音乐有助于纾解人们的压力, 现已成为大众娱乐的一种重要方式。互联网的发展使人们听音乐变得方便, 但同时也使得“信息过载”的问题变得日益严重。尽管各大公司平台纷纷推出了针对音乐的推荐系统来解决这个问题, 但现有传统的推荐系统并不能保证用户体验, 用户对精准推荐的需求仍很强烈。为解决“信息过载”问题的同时并保证用户体验, 本文提出了基于状态转移的奖励值算法。该算法包括对用户自身喜好建模, 并利用用户集数据提出的音乐流行度和用户从众度, 根据用户喜好、音乐流行度以及状态转移概率定义奖励函数。所提出的算法能个性化地对音乐库数据进行筛选和聚类。在对数据进行处理时, 采用 Davies-Bouldin 指数对声乐特征进行离散化。在模型训练时, 采用基于列表距离最小化的计算方法对参数进行选择。通过在 Million Song Dataset 开源音乐数据集上的实验, 表明在算法中加入音乐流行度对推荐效果有一定影响, 本文所给出的推荐算法能够提高推荐的效果, 说明了本文算法的有效性。

**关键词:** 音乐推荐; 用户偏好; 状态转移; 奖励函数; 离散化

**中图分类号:** TP391      **文献标识码:** A      **文章编号:** 0490-6756(2018)04-0719-08

## Research on music recommendation of reward value based on state transfer

TAN Bin<sup>1</sup>, SUN Jie-Ping<sup>2</sup>, JU Sheng-Gen<sup>2</sup>, LI Wei<sup>1</sup>

(1. Jinjiang College of Sichuan University, Pengshan 620860, China;

2. College of Computer Science, Sichuan University, Chengdu 610065, China)

**Abstract:** Listening to music is helpful in relieving the pressure of people, and has become a major entertainment for the general public. The development of the Internet makes it convenient for people to listen to music, but it also makes the problem of “information overload” more and more serious. Although many internet companies have launched music recommendation system to solve the problem, the existing recommendation systems cannot guarantee good user experience. As a result, there is still a popular demand for precise recommendation for music. In order to solve the problem of “information overload” and guarantee good user experience at the same time, this paper presents a reward value algorithm based on state transition. Specifically, the user preference model is first built; then, the music popularity and user conformity is proposed based on user data; finally, the reward function is defined based on user preference, music popularity and state transition probability. The proposed algorithm can individually screen and classify the data from the music library. In the algorithm, the Davies-Bouldin exponent is used to discretize vocal characteristics when processing data; the algorithm based on list distance minimization is used to select parameters during the model training. The experiments are conducted on the Million Song Dataset, and the results show that the music popularity has certain influence on the recom-

收稿日期: 2017-12-18

基金项目: 国家自然科学基金(61332066)

作者简介: 谭斌(1975—), 男, 硕士, 研究方向为数据库与知识工程. E-mail: tanb\_ice@163.com

通讯作者: 瑶生根. E-mail: jsg@scu.edu.cn

mendation effect of the algorithm. The recommendation algorithm proposed in this paper can improve the performance of recommendation, which proves the effectiveness of the proposed algorithm.

**Keywords:** Music recommendation; User preference; State transition; Reward function; Discretization

## 1 引言

随着互联网技术的发展以及个人智能设备的普及,“信息过载”<sup>[1]</sup>问题日益严重。据估计,Facebook 每日有 3000 万张以上的照片从后台被上传,后台日志数据每天就能生成 300 TB;国内的某电子商务网站,每天达成的交易在千万笔级别,每日日志文件超过 50 TB<sup>[2,3]</sup>。面对如此情况,各大平台纷纷推出搜索功能,但在某些情况下,用户并没有明确的搜索对象,例如,想看一部电影或者听几首歌,但没有明确要看哪一部或者听哪一首,这时,搜索技术就不能满足用户此时需求,在此情景下,推荐算法应运而生,极大便利了用户在此类情景下的信息选择。推荐算法在社交、电子商务、影音娱乐以及新闻筛选等领域得到了广泛应用,并在市场范围内有不俗的表现<sup>[4]</sup>。

目前的推荐算法,无论是基于内容的推荐、协同过滤亦或是混合推荐,利用用户的历史数据,分析用户的喜好,找到邻近用户,预测用户未来的选择。Lieberman 等人<sup>[5]</sup>在强化学习的框架中,基于音乐的 35 维特征向量提出一种搜索方法,每一个声学特征又被量化为 100 段,加入了音乐列表奖励机制,根据反馈值推荐音乐列表。该方法将每一类特征统一量化为 100 段,可能导致某些维度上会出现数据稀疏性问题,同时该模型忽略了特征权重; Sánchez-Moreno 等人<sup>[6]</sup>将播放计数引入到 CF 算

法中,建立用户的模糊集群,该算法基于用户播放次数和艺术家特点来度量用户喜好,这种度量准则不够全面。总体来讲,前人音乐推荐算法存在以下四个方面的问题:(1) 基于内容的推荐单一地考虑用户的偏好与用户偏好相近的音乐,并未对用户整体喜好与整个音乐库的分布联系起来,导致难有新的喜好的认知发现;(2) 对特征离散化较为固定,没有对每一维特征做分析;(3) 过度依赖音乐评分信息,每位用户对项目的认知不同,对项目的打分标准就不同;(4) 用户冷启动和项目冷启动。

本文在基于前人研究音乐推荐应用声学特征的基础上,考虑用户选择受社会环境因素,使得推荐算法更具个性化,更符合实际情况。更深层次地考虑用户选择音乐时,歌曲间过渡的规律,其中状态转移是由状态转移概率矩阵来刻画,状态转移概率矩阵由用户个人状态转移概率矩阵和整体转移矩阵两部分构成,用户个人概率矩阵个性化地描述用户听音乐的习惯规律,整体转移矩阵描述音乐转移过渡的一般情况,以期望修正用户历史数据中噪声数据造成的偏差,同时可以解决用户冷启动的问题。定义奖励函数,并且根据候选推荐列表在线更新用户偏好,在限定时间内,在生成的多个候选列表中选择总奖励值最高的作为最终推荐列表。在训练奖励函数中的参数时,采用基于列表相似度的调参法进行参数更新,使得以奖励值作为挑选参照的方式更加准确。本文的算法框架图如图 1 所示。

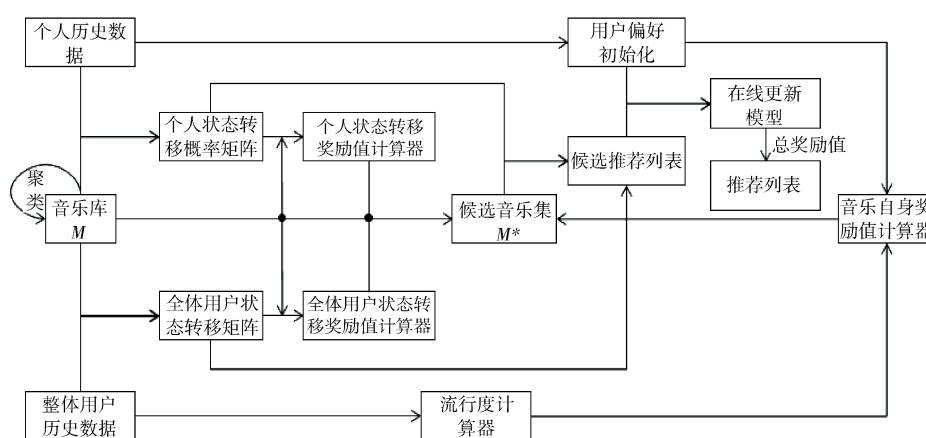


图 1 算法框架图  
Fig. 1 Algorithm framework diagram

## 2 特征选择及数据离散化

通过对音乐声学特征的研究,文献[7,8]都通过节奏、音色、响度、音高这几个声学特征将一首音乐分类。考虑到不同年龄层次的用户会对某些年代的歌曲会有更强烈的喜好,本文算法另外加入音乐的年代特征。

本文借用 the Echo Nest 专业分析工具得出音乐的声乐特征,并将之量化,同时得到音乐的年代属性。本文选择节奏、音色、响度、音高这四种声学特征以及歌曲的年代属性这一特征组成一首音乐的 34 维特征向量。特征向量具体组成如表 1 所示。

表 1 特征向量中属性的选择和索引

Tab. 1 Selection and indexing of attributes in feature vectors

特征属性	维度索引
音乐节奏	1
节拍	2
主调	3
30% 及 70% 处的响度	4,5
响度的均值与方差	6,7
音高域	8-19
音高的方差	20
平均音色	21-32
音色变化方差	33
年代	34

本文提取的原始数据,由于数值趋于连续,不利于分类聚类等操作,因此,需要将特征向量的每一维进行离散化处理。离散化具体步骤如下。

(1) 对音乐库中所有音乐特征向量的每一维数据进行 K-Means 聚类,确定离散化段数  $K$ 。

(2) 每一维数据排序后按照数目均匀划分成  $K$  段。

(3) 计算每一段的均值,作为该段所有数据的离散化数值。

其中,段数  $K$  的取值依据聚类算法的评估指数——Davies-Bouldin 指数(DBI)<sup>[9]</sup>。DBI 通常用于评价无监督聚类时聚类个数对聚类效果的影响, DBI 值越小,类内距离越小,类间距离越大,聚类效果越好。本文采用使 DBI 值最小的聚类个数  $K$  为该维属性的离散段数。

## 3 考虑状态转移的奖励值函数

参照强化学习中奖励函数的作用,奖励值在本文算法中是挑选音乐的数值依据。本文的奖励函数

定义如式(1)所示。

$$R = R_s(song_i) + R_t(s_{i-1}, song_i) \quad (1)$$

式(1)中,第一部分的  $R_s(song_i)$  为基于用户偏好形成的奖励值,由  $R_s(song_i) = \varphi_s(u) \cdot \omega_s \cdot \theta_s(song_i) + \alpha \cdot c_u \cdot TP(song_i)$  确定,  $\varphi_s(u)$  是用户  $u$  的个性化偏好,由用户的历史数据迭代分析而来,  $\theta_s(song_i)$  是音乐  $song_i$  的特征向量,  $\beta$  是  $\theta_s(song_i)$  每一维的权重,用来度量  $\theta_s(song_i)$  每一维特征属性对奖励值的贡献度,  $c_u$  是用户  $u$  的从众度,由用户个性化自定义,  $TP(song_i)$  同样表示音乐  $song_i$  的流行度,  $\alpha$  是  $TP(song_i)$  的放大因子,在训练模型中是个可调参数;第二部分  $R_t(s_{i-1}, song_i)$ , 度量的就是音乐间状态转移过渡对当前局面产生的影响。由式(2)定义。

$$R_t(s_{i-1}, song_i) =$$

$$\sum_{song_i \in C} \left[ \omega_u P_u(song_i | song_{i-1}) \cdot \frac{1}{o(song_i, c_j)} + \omega_z P_z(song_i | song_{i-1}) \cdot \frac{1}{o(song_i, c_j)} \right] \quad (2)$$

其中,  $o(song_i, c_j)$  是  $song_i$  与  $c_j$  的欧氏距离,  $c_j$  指  $j$  簇的聚类中心,  $P_u(song_i | song_{i-1})$  和  $P_z(song_i | song_{i-1})$  分别指用户  $u$  个性化的  $song_{i-1}$  到  $song_i$  的转移概率和用户总体  $song_{i-1}$  到  $song_i$  的转移概率。

## 4 状态转移概率和状态转移奖励值

在有限的状态空间中,从状态  $s_0$  转移到状态  $s_1$  的概率是一定的,用  $P(s_1 | s_0, song_1)$  表示。本文中,该概率描述用户听完上一首音乐后,听下一首音乐的可能性。

由于音乐集中音乐数目大,相比较下用户历史播放列表中的音乐数据小,若在推荐中一一考虑用户在听完历史列表音乐状态下,听音乐集中某首音乐的转移概率,这个数据无疑是稀疏的。因此,本文考虑在音乐集  $M$  聚类后簇与簇间的转移概率,基于这个假设,本文提出了基于音乐集  $M$  的簇间状态转移模型。

簇间状态转移概率模型遍历用户历史播放列表后得到。聚簇个数在模型训练时是可调参数,按照式(2)的定义  $P(song_i | song_{i-1})$  表示  $song_{i-1}$  到  $song_i$  的转移概率,实则,其具体取值为  $song_{i-1}$  所属的簇到  $song_i$  所属簇的簇间转移概率。本文除了计算用户个人的状态转移概率之外,还考虑用户总体的状态转移概率模型,以此均衡个人状态转移的偏差。

假设用户  $u$  的历史播放列表为  $\{song_1, song_2, \dots, song_{12}\}$ , 根据聚类后的音乐集  $M$ , 如图 2 所示(假设此时聚类个数  $K=5$ ). 一一计算用户历史列表中的 12 首音乐与聚类中心的距离, 选择距离近的划分到相应的簇中. 如图 3 所示.

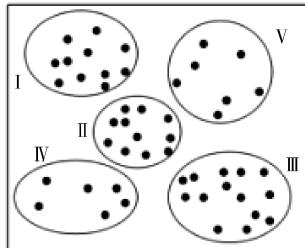


图 2 聚类后的音乐集  
Fig. 2 Clustered music set

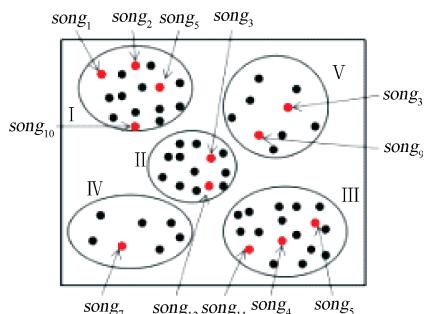


图 3 播放列表中音乐位置  
Fig. 3 Music position in playlist

考虑音乐的播放顺序, 即  $song_1 \rightarrow song_2 \rightarrow \dots \rightarrow song_{12}$ , 那么根据播放顺序而发生的簇间的转移情况如表 2 所示. 由此可以计算出, 用户  $u$  在该聚类情况下簇间的转移概率如表 3 所示.

表 2 簇间转移情况

Tab. 2 The situation of intercluster transfer

音乐播放顺序	簇间转移	音乐播放顺序	簇间转移
$song_1 \rightarrow song_2$	I $\rightarrow$ I	$song_7 \rightarrow song_8$	IV $\rightarrow$ V
$song_2 \rightarrow song_3$	I $\rightarrow$ II	$song_8 \rightarrow song_9$	V $\rightarrow$ V
$song_3 \rightarrow song_4$	II $\rightarrow$ III	$song_9 \rightarrow song_{10}$	V $\rightarrow$ I
$song_4 \rightarrow song_5$	III $\rightarrow$ III	$song_{10} \rightarrow song_{11}$	I $\rightarrow$ III
$song_5 \rightarrow song_6$	III $\rightarrow$ I	$song_{11} \rightarrow song_{12}$	III $\rightarrow$ II
$song_6 \rightarrow song_7$	I $\rightarrow$ IV		

表 3 簇间转移概率

Tab. 3 Probability of intercluster transfer

终止簇	起始簇				
	I	II	III	IV	V
I	25%	0	33.3%	0	50%
II	25%	0	33.3%	0	0
III	25%	100%	33.4%	0	0
IV	25%	0	0	0	0
V	0	0	0	100%	50%

同理, 整体用户的状态转移概率矩阵  $P_z$  ( $song_i | song_{i-1}$ ). 如图 4 所示, 是当前音乐集  $M$  及用户历史列表的状态  $s_0$ , 候选推荐列表为  $L$ ,  $song_{L1}$  和  $song_{L2}$  是  $L$  的第一首音乐和第二首音乐, 如图 5 和图 6 所示.

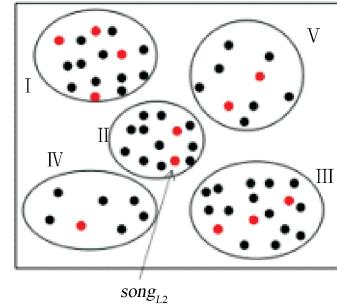


图 4 状态  $s_0$   
Fig. 4 State  $s_0$

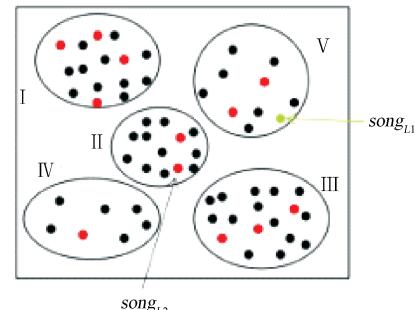


图 5 状态  $s_1$   
Fig. 5 State  $s_1$

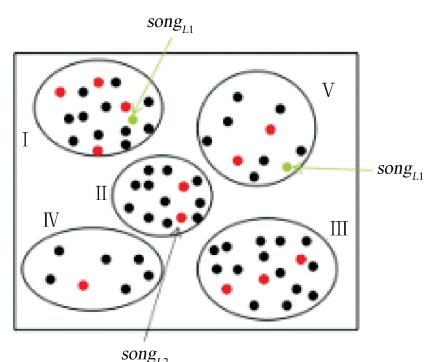


图 6 状态  $s_2$   
Fig. 6 State  $s_2$

在局面状态为  $s_0$  时, 考虑添加  $song_{L1}$  后的状态转移奖励

$$R_t(s_0, song_{L1}) =$$

$$\sum_{c_j, song_{L1} \in c_j, j=1}^{j=5} P(song_{L1} | song_{12}) \cdot \frac{1}{o(song_{L1}, c_j)}$$

其中,  $\frac{1}{o(song_{L1}, c_j)}$  表示  $song_{L1}$  与各聚类中心点的欧氏距离的倒数, 距离值越小, 与该簇相关联产生

的状态转移奖励越大.

所谓状态叠加, 是指将  $song_{L1}$  做推荐后, 局面由  $s_0$  变为  $s_1$ , 由于在此聚类情况下属于 V 簇, 因此, 在计算  $song_{L2}$  的状态转移奖励时, 状态转移概率带入第 V 簇的簇间转移概率.

同理, 基于整体用户的状态转移奖励值也可根据  $P_z(song_i | song_{i-1})$  计算得到, 用户个人状态转移奖励值与基于整体用户的状态转移奖励值由  $\omega_u$  和  $\omega_z$  两个权重均衡.

## 5 用户偏好的初始化和在线更新

本文模型的最终输出是一个长度为  $X$  的音乐推荐列表, 用户偏好  $\varphi_s(u)$  是衡量用户喜好的标准, 为了体现用户对不同候选列表的感知, 在用历史列表初始化后, 根据不同的候选列表将用户偏好进行在线更新, 以便响应对应的候选列表, 便于精准计算每个候选列表的总奖励值.

按照奖励函数定义公式, 本章模型首先需要对用户偏好进行初始化, 初始化模型如式(2)和式(3)所示.

遍历历史列表中每一首音乐, 如式(2).

$$\varphi_s(u) = \varphi_s(u) + \frac{n(song_i)}{\sum_{j=1}^{m-X}} \theta_s(song_i)^T \quad (2)$$

遍历音乐库中每首音乐的每一维特征属性, 如式(3).

$$\begin{aligned} Variance[i] &= \\ &\frac{1}{m-X} \sum_{j=1}^{m-X} [\theta_s(song_j)[i] - \bar{\theta}_s(song)[i]]^2 \\ \beta[i] &= 1 + \frac{1}{Variance[i]} \quad (3) \end{aligned}$$

初始化的用户偏好代表了用户最初的喜爱, 该喜好根据不同的候选推荐列表更新. 本算法式(1)定义的奖励值函数, 计算每首音乐的奖励值, 根据  $R(song_i)$  排序, 按照从大到小顺序, 选取  $0.3 T$  大小的音乐集  $M^*$  作为候选音乐集.

用户偏好  $\varphi_s(u)$  会根据每个候选推荐列表  $L$  分别在线更新, 候选推荐列表的生成方法如下步骤.

(1) 按照历史列表中训练数据的最后一首音乐所属类, 检索  $P_u(song_i | song_{i-1})$  和  $P_z(song_i | song_{i-1})$ , 在转移概率非 0 的簇内选择奖励值最大的音乐, 作为候选推荐列表  $L$  的第一首音乐.

(2) 如果用户  $u$  的历史播放列表  $HL$  长度  $m$

$> 20$ , 检索  $P_u(song_i | song_{i-1})$  在转移概率非 0 的簇内选择奖励值最大的音乐, 作为候选推荐列表  $L$  的第  $i$  首音乐; 如果用户  $u$  的历史播放列表  $HL$  长度  $m \leq 20$ , 检索  $P_z(song_i | song_{i-1})$  在转移概率非 0 的簇内选择奖励值最大的音乐, 作为候选推荐列表  $L$  的第  $i$  首音乐.

(3) 以此类推, 得到长度为  $X$  的候选推荐列表  $L$ .

得到候选推荐列表  $L$  后, 用户偏好  $\varphi_s(u)$  进行在线更新, 更新方法如下步骤.

遍历候选推荐列表  $L$ .

$$r_i = R_s(song_i)$$

$$\bar{r} = average(r_1, r_2, \dots, r_{i-1})$$

$$r_{ince} = \log\left(\frac{r}{\bar{r}}\right)$$

$$\varphi_s = \frac{i}{i+1} \varphi_s + \frac{1}{i+1} \theta_s \cdot r_{ince}$$

其中,  $r_i$  为在当前状态下用户听完  $song_i$  产生的立即奖励, 即算法 4-3 中计算得到的  $R_s(song_i)$ ,  $\bar{r}$  为目前为止的平均奖励, 本文定义  $r_{ince} = \log\left(\frac{r}{\bar{r}}\right)$ , 该变量可以决定下一首音乐的选择对当前更新是否有增益, 例如, 若  $r < \bar{r}$ , 则  $r_{ince}$  是个负数, 对参数更新产生负面影响. 最后, 模型为更新  $\varphi_s(u)$  分配的权值之和为 1. 综上所述, 本文算法总体实现参见算法 1.

### 算法 1 基于状态转移的奖励值算法

**输入:** 用户  $u$  的历史播放列表  $HL$ , 音乐集中歌曲的流行度, 音乐集  $M$ , 音乐集  $M$  大小  $T$ , 推荐列表长度  $X$ , 聚类个数  $C$ , 定时器  $clock$

**输出:** 推荐音乐列表  $L^*$

1) 初始化用户偏好及音乐特征向量权重

2) 计算两个状态转移概率矩阵

3) 将音乐集  $M$  篩减成  $M^*$  并聚类;

4) 生成候选列表  $L$ ;

5) 针对列表  $L$  对用户偏好在线更新, 得到  $\varphi_s^L(u)$ ;

6) 计算  $L$  中每首音乐到各个聚类中心  $c_j$  的欧式距离  $o(song, c_j)$

7)  $R =$

$$\sum_{i=1}^X \left[ \begin{array}{l} \varphi_s(u) \cdot \beta \cdot \theta_s(song_i) + c_u \cdot \alpha \cdot TP(song_i) + \\ \sum_{\substack{j=1 \\ c_j, song_i \in c_j}}^X \left[ \begin{array}{l} \omega_u P_u(song_i | song_{i-1}) \cdot \frac{1}{o(song_i, c_j)} \\ + \omega_z P_z(song_i | song_{i-1}) \cdot \frac{1}{o(song_i, c_j)} \end{array} \right] \end{array} \right]$$

```

if    $R(L) > \max R(L)$  then
   $\max R(L) = R(L)$ 
   $L^* = L$ 
  End if
Until clock=0
8) 返回  $L^*$ 

```

## 6 实验

### 6.1 实验数据

本文理论,选择哥伦比亚大学整理的 Million Song Dataset 开源音乐数据<sup>[10]</sup>. Million Song Dataset 免费为研究者提供了音乐音频特征及其他元数据,鼓励商业规模大小的算法研究. 选取表 1 中提到的特征属性,并从 The Million Song Dataset 数据集中得到真实用户音乐列表,本文对数据进行了划分,具体如表 4 和表 5 所示.

表 4 用户数据划分

Tab. 4 User data division

训练集	测试集
2394	1197

表 5 测试集分组

Tab. 5 Test set grouping

组别	用户组 1	用户组 2	用户组 3
样本数目	384	325	488

表 6 特征向量各维度离散段数

Tab. 6 The number of discrete segments in each dimension of the feature vector

特征维度	1. 节奏	2. 节拍	3. 主调	4. 30th 响度	5. 70th 响度	6. 平均响度
离散段数	14	4	10	20	15	15
特征维度	7. 响度方差	8. 音高 1	9. 音高 2	10. 音高 3	11. 音高 4	12. 音高 5
离散段数	16	19	18	19	17	20
特征维度	13. 音高 6	14. 音高 7	15. 音高 8	16. 音高 9	17. 音高 10	18. 音高 11
离散段数	17	15	19	17	10	15
特征维度	19. 音高 12	20. 音高方差	21. 音色 1	22. 音色 2	23. 音色 3	24. 音色 4
离散段数	15	19	12	19	14	13
特征维度	25. 音色 5	26. 音色 6	27. 音色 7	28. 音色 8	29. 音色 9	30. 音色 10
离散段数	13	17	20	17	16	18
特征维度	31. 音色 11	32. 音色 12	33. 音色方差	34. 年代		
离散段数	19	18	2	4		

6.2.2 参数实验 首先定义两个列表间的距离,如式(4).

$$dis\_list = \frac{\sum_{i=1}^X (song_{list1\_i} - song_{list2\_i})}{X} \quad (4)$$

本文将数据按照 2 : 1 的方式划分为训练集和测试集,测试集又分为 3 组子集,以供多组测试实验.

### 6.2 算法实验

6.2.1 数据离散化 一首音乐由一个 34 维特征向量唯一表示,需要对每一维做离散化处理.

图 7 所示的是关于节奏,音乐 30 分位、70 分位处响度大小,平均响度及响度方差的 DBI 值. 聚类个数均为 2 到 20, K-Means 迭代次数为 100. 节奏这一特征在  $K=14$  时取得最小值 0.471, 说明该维特征分为 14 类时效果最好,因此,本文将该维特征离散化成 14 段,每一段值取该段的均值. 以此类推,如表 6 所示,为每一维的离散化段数.

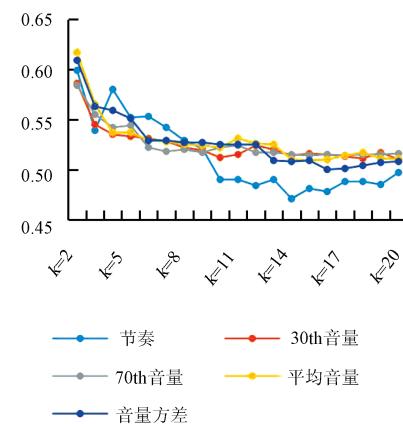


图 7 部分特征属性聚类 DBI 值  
Fig. 7 Some feature attributes cluster DBI values

其中,  $song_{list1\_i} - song_{list2\_i}$  表示两首音乐间的距离;  $X$  是列表长度.

在 2394 位用户中,历史播放列表长度  $\geq 30$  的用户共 1843 个,在此用户集上进行调参实验. 对权重  $\omega_u$  的优化实验如图 8 所示. 纵坐标表示列表距离.

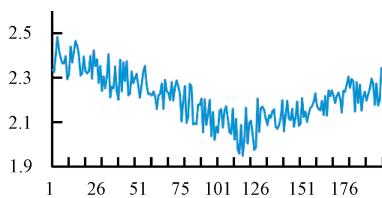
图 8 参数  $\omega_u$  对推荐效果的影响

Fig. 8 The effect of parameter  $\omega_u$  on recommendation effect

由图 8 可以看出, 当  $\omega_u$  在(1, 200)内变化时, 列表距离的变化域大致范围是(1.95, 2.48), 当  $\omega_u = 116$  时, 取得最小值。

对权重  $\omega_z$  的优化实验如图 9 所示。由图知当  $\omega_z$  在(1, 200)内变化时, 列表距离的变化域大致范围是(1.89, 2.15), 当  $\omega_z = 41$  之后, 波形有震荡, 但是总体趋势不再变化, 因此, 算法中, 对  $\omega_z$  的值设置为 41。

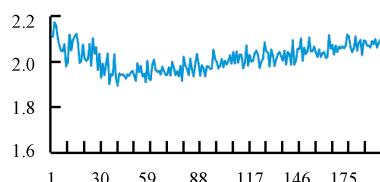
图 9 参数  $\omega_z$  对推荐效果的影响

Fig. 9 The effect of parameter  $\omega_z$  on recommendation effect

同理, 参数  $\alpha$  和  $\beta$  的取值分别为 7.1 和  $0.8 \cdot \beta$  初始, 聚类个数为 28。

### 6.2.3 算法对比和分析

将本文所提算法与传统推荐算法中随机推荐和 K-NN 算法以及前人算法文献[5](Lieberman)和文献[11](Chen)进行比较, 以验证本文算法的有效性。

在用户组 1 上进行比较, 结果如图 10 和图 11 所示。由两组数据看出, 本文算法在用户组 1 上的表现, 优于传统的推荐算法。与前人的算法相比较, RMSE 与 Lieberman 算法比较, 降低 39.8 个百分点, 与 Chen 的算法比较, 降低 29.2 个百分点, 皮尔逊相似系数优于 Lieberman 的算法 8.5 个百分点, 优于 Chen 的算法 3.2 个百分点, 呈强相关。

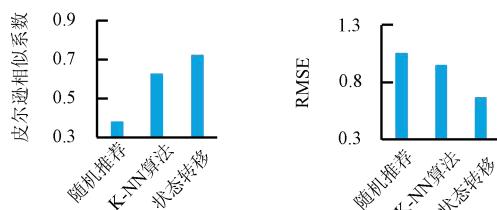


图 10 传统算法与本文算法在用户组 1 的结果

Fig. 10 The result of the traditional algorithm and the algorithm of this article in the user group 1

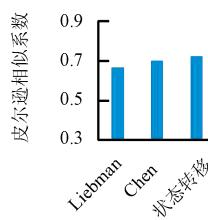


图 11 前人算法与本文算法在用户组 1 的结果

Fig. 11 The results of the previous algorithm and the algorithm of this article in the user group 1

在用户组 2 上, 进行算法的对比, 如图 12 和图 13 所示。

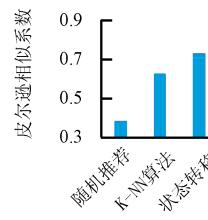


图 12 传统算法与本文算法在用户组 2 的结果

Fig. 12 The result of the traditional algorithm and the algorithm of this article in the user group 2

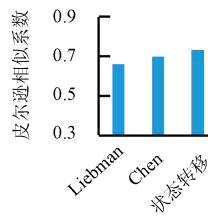


图 13 前人算法与本文算法在用户组 2 的结果

Fig. 13 The results of the previous algorithm and the algorithm of this article in the user group 2

由上面的两组数据看出, 本文算法在用户组 2 上的表现, 优于传统的推荐算法。与前人的算法相比较, RMSE 与 Lieberman 算法比较, 降低 27 个百分点, 与 Chen 的算法比较, 降低 11.2 个百分点, 皮尔逊相似系数优于 Lieberman 的算法 10.7 个百分点, 优于 Chen 的算法 5.0 个百分点, 呈强相关。

在用户组 3 上, 进行算法的对比。如图 14 和图 15 所示。

由上面的两组数据看出, 本文算法在用户组 3 上的表现, 同样优于传统的推荐算法。与前人的算法相比较, RMSE 与 Lieberman 算法比较, 降低 27.6 个百分点, 与 Chen 的算法比较, 降低 11.8 个百分点, 皮尔逊相似系数优于 Lieberman 的算法 11.2 个百分点, 优于 Chen 的算法 5.1 个百分点, 呈强相关。

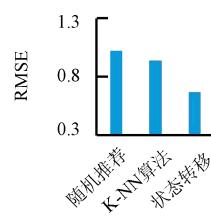
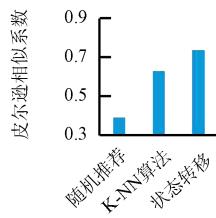


图 14 传统算法与本文算法在用户组 3 的结果  
Fig. 14 The result of the traditional algorithm and the algorithm of this article in the user group 1

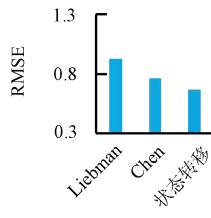
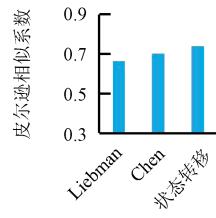


图 15 前人算法与本文算法在用户组 3 的结果  
Fig. 15 The results of the previous algorithm and the algorithm of this article in the user group 3

综上数据,基于状态转移的奖励值算法表现强于前人算法,算法改进有效.

## 7 结 论

针对当前音乐推荐算法的不足,本文以巧妙引入奖励值的概念,将音乐顺序纳入研究范围,将用户选择怎样的音乐列表视作马尔可夫决策过程,推荐音乐列表的每一首音乐,都视作决策过程中状态的变化,因此,不同状态会对当前局面产生不同的奖励值,算法选择奖励值最大的状态序列,在此即为奖励值最大的音乐列表.同时,将用户个人历史数据与整体用户数据做均衡,优化推荐效果,创新地加入音乐流行度和用户从众度,提出了基于状态转移的奖励值算法.

本文基本完成了模型的主要任务.基于时间和实验条件的约束,还有很多地方需要改进.如,除音乐的声乐特征之外,还可考虑歌词的语义特征,加入情感分析,完善对音乐集的聚类及分类.另外,在保证目前的模型训练时间和算法运行时间的同时,未来可以考虑如何更细致分析用户偏好,将用户客观属性加以考虑,提高推荐准确度.

## 参 考 文 献:

- [1] Zhou Z, Liu M, Zhang F, et al. A data processing framework for IoT based online monitoring system [C]// IEEE, International Conference on Computer Supported Cooperative Work in Design. [s. l.]: IEEE, 2013.
- [2] Chen W, Niu Z, Zhao X, et al. A hybrid recommendation algorithm adapted in e-learning environments [J]. World Wide Web, 2014, 17: 271.
- [3] Crespo R G, Martínez O S, Lovelle J M C, et al. Recommendation system based on user interaction data applied to intelligent electronic books [J]. Comput Human Behavior, 2011, 27:1445.
- [4] 张玉洁, 杜雨露, 孟祥武. 组推荐系统及其应用研究[J]. 计算机学报, 2016, 39: 745.
- [5] Liebman E, Saartsehansky M, Stone P. DJ-MC: A reinforcement-learning agent for music playlist recommendation [J]. Comput Sci, 2014.
- [6] Sánchez-Moreno D, González A B G, Vicente M D M, et al. A collaborative filtering method for music recommendation using playing coefficients for artists and users [J]. Expert Syst Appl, 2016, 66: 234.
- [7] Trevarthen C, Delafield-Butt J T, Schögler B. Psychobiology of musical gesture: innate rhythm, harmony and melody in movements of narration [J]. New Perspect Music Gesture, 2011, 6: 754.
- [8] Ventura M D. The influence of the rhythm with the pitch on melodic segmentation [M]// Intelligent Data Analysis and Applications. [s. l.]: Springer International Publishing, 2015.
- [9] Davies D L, Bouldin D W. A cluster separation measure [J]. IEEE Trans Pattern Anal Mach Intell, 1979, 2: 224.
- [10] Thierry B M, Daniel P W, Ellis B W, et al. The million song dataset [C]// Proceedings of the 12th International Society for Music Information Retrieval Conference (ISMIR 2011). [s. l.]: [s. n.], 2011.
- [11] Chen S, Moore J L, Turnbull D, et al. Playlist prediction via metric embedding [C]// ACM Knowledge Discovery and Data Mining. [s. l.]: [s. n.], 2012.

## 引 用 本 文 格 式:

- 中 文: 谭斌,孙界平,琚生根,等. 基于状态转移的奖励值音乐推荐研究[J]. 四川大学学报: 自然科学版, 2018, 55: 719.
- 英 文: Tan B,Sun J P,Ju S G,et al. Research on music recommendation of reward value based on state transfer [J]. J Sichuan Univ: Nat Sci Ed, 2018, 55: 719.