

# 基于多模态的冷启动饮食推荐算法研究与实现

涂帅<sup>1</sup> 黄锦鸿<sup>2</sup> 朱珍民<sup>2\*</sup>

<sup>1</sup>(湘潭大学 湖南 湘潭 411105)

<sup>2</sup>(中国科学院计算技术研究所 北京 100080)

**摘要** 为帮助用户在海量食谱中找到符合个人饮食偏好食谱,提出一种基于多模态的饮食偏好推荐冷启动算法。该算法分为线上和线下两个阶段。线下阶段,通过表示学习获得食谱各维度信息的语义向量。线上阶段,基于迭代、图相似度传播的思路,通过少量食谱的偏好反馈获得用户对全部食谱的偏好度并推荐。实验结果表明,基于多模态的冷启动饮食推荐算法在实验平台上的准确率达到实际工程应用水平。

**关键词** 饮食推荐 冷启动 多模态

中图分类号 TP391

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.04.012

## RESEARCH AND IMPLEMENTATION OF COLD START DIET RECOMMENDATION ALGORITHM BASED ON MULTI-MODAL

Tu Shuai<sup>1</sup> Huang Jinhong<sup>2</sup> Zhu Zhenmin<sup>2\*</sup>

<sup>1</sup>(Xiangtan University, Xiangtan 411105, Hunan, China)

<sup>2</sup>(Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100080, China)

**Abstract** In order to help users find recipes in line with their personal dietary preferences from a large number of recipes, a cold start algorithm for dietary preference recommendation based on multi-modal is proposed. The algorithm was divided into online and offline phases. In the offline stage, the semantic vector of each dimension of recipe information was obtained through representation learning. In the online stage, based on the idea of iteration and graph similarity propagation, the user's preference for all recipes was obtained and recommended through a small amount of preference feedback of recipes. The experimental results show that the accuracy of the cold start diet recommendation algorithm based on multi-modal achieves the level of practical engineering application.

**Keywords** Diet recommendation Cold start Multi-modal

## 0 引言

过去十年来,互联网上出现了数以百万计的食谱,用户面对着饮食领域的信息过载,从海量的数据中寻找符合个性化需求的食谱变得越来越困难。近年来推荐系统已在多种场景下发挥重要作用,它可以帮助用户克服信息过载问题,协助用户进行决策甚至改变用户的行为。由于商业化等原因,虽然推荐系统近年来在电子商务等领域得到了快速的发展,但在饮食推荐

领域的研究则受到较少的关注。

随着饮食问题日益受到重视,关于饮食推荐系统的研究正在快速发展,通过饮食推荐系统帮助用户找到符合用户饮食偏好的食谱是非常有意义的。而现有饮食推荐算法大多假设已有大量的用户历史交互信息,忽视了饮食偏好推荐系统冷启动阶段。系统冷启动需要在没有用户数据沉淀,只有物品相关信息的情况下,让推荐结果尽量符合用户需求。即使在有少量用户历史数据时,部分基于协同过滤(CF)的饮食偏好推荐方法通过矩阵分解(MF)等经典算法对用户-食谱

矩阵的稀疏问题也仅起到一定程度的缓解<sup>[1-4]</sup>。忽视系统冷启动问题将显著降低初期用户体验。

目前除了仅基于视觉信息的在线饮食偏好冷启动系统 Yum-me<sup>[5]</sup> 和 Plateclick<sup>[6]</sup>, 少有关于饮食偏好推荐系统冷启动问题的研究<sup>[7-8]</sup>。值得注意的是, 食谱的选择是受食谱外观、烹饪工艺、口感、饮食禁忌、用户个人健康状态等多因素影响的复杂过程<sup>[9]</sup>, 且不同用户对不同因素的重视程度不同。Yum-me<sup>[5]</sup> 和 Plateclick<sup>[6]</sup> 等仅基于视觉信息的冷启动方法存在明显的改进空间。考虑更多饮食因素的饮食偏好推荐系统冷启动方法有助于显著改善用户体验, 有重要的实用和商业价值。故此, 提出一种基于多模态的冷启动饮食推荐方法(MCS4FPR), 弥补现有方法的不足。

## 1 基于多模态饮食推荐冷启动算法

这是一种基于食谱多模态语义向量相似度的迭代冷启动算法。与现有饮食推荐方法仅基于视觉信号进行冷启动不同, MCS4FPR 方法考虑了食谱丰富的多模态信息, 主要包括食谱外观图像、烹饪工艺、口感、菜系等信息, 同时考虑了不同用户对食谱各维度信息关注度的不同。该算法分线上线下两阶段。线下阶段, 该算法通过多种语义嵌入算法, 获得食谱不同维度信息的语义向量。在线上阶段, 首先通过客户端获取用户对食谱各维度信息的自定义关注度, 用于计算加权的食谱多模态语义向量相似度。然后迭代地为用户展示食谱列表, 并将用户偏好反馈结果在加权相似度连接图中进行传播。迭代结束后即可获得用户对所有食谱的偏好排序列表, 用于饮食偏好推荐。整个过程最重要的是饮食偏好度迭代传播算法的设计、多维度食谱信息语义向量的表示学习、用户自定义的加权语义相似度计算。

### 1.1 饮食偏好度迭代传播算法设计

算法步骤可描述如下:

(1) 用户通过客户端选择对不同食谱维度信息的关注度, 具体为通过星条图打分, 然后进入后三个步骤组成的循环迭代流程。

(2) 后台每次根据当前用户对各个食谱的偏好度向量  $\mathbf{P}$ , 选取  $k$  个代表性食谱发送给客户端。

(3) 客户端向用户呈现  $k$  个代表性食谱的信息(菜名、菜系、口味、主料、图片等), 然后收集用户反馈并返回给算法后台。

(4) 算法后台根据当前迭代轮次用户的反馈结果, 通过后台的综合语义相似度进行偏好度传播, 更新

偏好度向量  $\mathbf{P}$ 。

步骤(4)具体迭代过程如算法1所示。

#### 算法1 用户饮食偏好度迭代传播算法

输入:  $S_{\text{all}}, T$ 。

输出:  $\mathbf{P}_t = [P'_1, P'_2, \dots, P'_N]$ 。

1.  $B_0 = \varphi, K_0 = \varphi, L_0 = \varphi, \mathbf{P}_0 = [1/N, 1/N, \dots, 1/N]$
2. for  $t \leftarrow 1$  to  $T$  do
3.  $[B_t, \mathbf{P}_t] \leftarrow \text{update}(S_{t-1}, L_{t-1}, B_{t-1}, \mathbf{P}_{t-1})$
4.  $S_t \leftarrow \text{select}(t, B_t, \mathbf{P}_t)$
5. If  $t$  equals  $T$  then
6. return  $\mathbf{P}_t$
7. Else
8. ShowToUser( $S_t$ )
9.  $L_t \leftarrow \text{WaitForSelection}()$

用户饮食偏好度基于迭代的思路, 在每次迭代过程中选择  $k$  个具有代表性的食谱通过客户端呈现给用户, 用户选择符合个人饮食偏好的食谱, 然后算法1以用户选择的偏好食谱为中心依据相似度向相邻食谱进行偏好度传递。为了更好地描述算法作如下说明。

$S_{\text{all}}$ : 所有食谱的总集合, 共有  $N$  个食谱。

$S_t$ : 第  $t$  次迭代时, 呈现给用户做偏好选择的食谱集合, 其包含的  $k$  个元素均来自集合  $S_{\text{all}}$ 。

$L_{t-1}$ : 第  $t-1$  次迭代时, 用户从  $S_t$  中选择出的符合个人饮食偏好的食谱集合, 其包含的  $m$  个食谱均来自集合  $S_{\text{all}}$ 。

$\mathbf{P}_t = [P'_1, P'_2, \dots, P'_N]$ : 经过  $t$  次迭代后, 用户对所有食谱的累计饮食偏好度分布向量,  $P'_i^{(0)}$  初始化为  $1/N$ 。

$\mathbf{U}^t = [U_1^t, U_2^t, \dots, U_N^t]$ : 当前第  $t$  次迭代, 算法通过用户偏好食谱集合  $L_t$  和食谱  $S_t$  中的非偏好食谱基于语义向量相似度进行偏好度传播后, 所有食谱的饮食偏好度分布向量。

$B_t$ : 截至目前第  $t$  轮迭代, 可视为已经被呈现(无论是否符合饮食偏好)的食谱集合, 包括  $S_t$  以及与  $S_t$  中元素足够相似的其他元素, 其中  $B_{t-1} \subseteq B_t, B_0 = \varphi$ 。

$F = \{f(x_1), f(x_2), \dots, f(x_n)\}$ :  $f(x_n)$  代表第  $n$  个食谱的特征向量,  $x_n$  是第  $n$  个食谱, 即  $f$  是特征抽取函数, 负责将  $x_n$  食谱图片、食谱标题、烹饪说明等多维度的信息抽取并转化为特征向量。

$\mathbf{y}^t = [y_1^t, y_2^t, \dots, y_N^t]$ : 用户在第  $t$  轮对  $B_t$  中呈现的食谱的偏好度标签。

对于每次迭代  $t$ , 本课题开发的系统后台会通过客户端根据第  $t-1$  次迭代呈现给用户的食谱集合  $S_{t-1}$  和用户认为符合其饮食偏好的结果集合  $L_{t-1}$ , 计算得到

$U^t = [U_1^t, U_2^t, \dots, U_N^t]$ , 而后根据  $U^t = [U_1^t, U_2^t, \dots, U_N^t]$  将用户截至第  $t-1$  次迭代时对  $N$  个食谱的累计饮食偏好度分布向量  $P_{t-1}$  更新为  $P_t$ , 同时将截至第  $t-1$  次迭代时已经被呈现给用户食谱集合  $B_{t-1}$  更新为  $B_t$ . 之后, 继续下一次迭代, 决定呈现给用户的食谱构成 ( $S_t$ ). 具体过程可见算法 1。

算法 1 中的 update 函数, 根据  $L_{t-1}$  中的第  $t-1$  次迭代时用户偏好食谱和  $L_{t-1} \setminus B_{t-1}$  非偏好食谱, 借鉴标签相似度传播算法<sup>[10]</sup> 获得当前第  $t$  次迭代用户对所有食谱的偏好度向量  $U^t$ 。

$y^t = [y_1^t, y_2^t, \dots, y_N^t]$  为用户在第  $t$  轮对  $B_t$  中呈现的食谱的偏好度标签, 如果第  $i$  个食谱属于  $L_{t-1}$ , 则  $y_i^t = 1$ , 若第  $i$  个食谱属于  $L_{t-1} \setminus B_{t-1}$ , 则  $y_i^t = -1$ , 否则  $y_i^t = 0$ .  $U^t$  可视为基于语义向量相似度对  $y^t$  的平滑处理。

为了降低算法复杂度, 对相似度与当前  $i$  食谱足够接近的  $j$  食谱进行传播。以有用户偏好反馈的食谱  $i (y_i \neq 0)$  为顶点,  $f_{\text{eature}_i}$  为  $i$  食谱的特征向量,  $f_{\text{eature}_j}$  为  $j$  食谱的特征向量, 为所有 ( $\cos(f_{\text{eature}_i}, f_{\text{eature}_j}) \geq \sigma$ ) 的节点  $j$  添加边 ( $i, j$ ), 构造局部图  $G^i$ , 如图 1 所示。




图 1 局部图  $G^i$

对于每个局部图  $G^i$ , 计算局部的  $u^i$  向量, 累加所有  $u^i$  向量 ( $y_i \neq 0$ ) 并正则化可得平滑结果  $U^t$ , 局部的  $u^i$  满足式(1)。

$$\min Q(u^i) = \sum_{j, \|f(x_i) - f(x_j)\| \leq \sigma}^N w_{ij} (y_i^t - u_j^i)^2 + \sum_{j, \|f(x_i) - f(x_j)\| \leq \sigma}^N (1 - w_{ij}) (u_j^i - y_j^t)^2 \quad (1)$$

式中:  $w_{ij}$  权重计算方式如式(2)所示;  $\sigma$  是超参数。

$$w_{ij} = \begin{cases} e^{-\frac{1}{2\sigma^2} \|f(x_i) - f(x_j)\|^2} & \cos(f_{\text{eature}_i}, f_{\text{eature}_j}) \geq \sigma \\ 0 & \cos(f_{\text{eature}_i}, f_{\text{eature}_j}) < \sigma \end{cases} \quad (2)$$

式(1)的左边项是平滑项, 即保证相近食谱的饮食喜好度接近, 帮助  $U^t$  学到  $y^t$  的平滑表示。右边项是拟合约束, 帮助  $U^t$  拟合用户在第  $t$  次迭代时对食谱的打分信息  $y^t$ 。

为了求得  $u^i$ , 我们对  $Q(u^i)$  进行求导并令其为 0, 结果如式(3)所示。

$$\frac{\delta Q(u^i)}{\delta u_{j, j \neq i}^i} = 2w_{ij} (u_j^i - u_i^i) + 2(1 - w_{ij}) (u_j^i - y_j^i) = 0 \quad (3)$$

令  $u_i^i = y_i^i$ , 可得式(4)。

$$u_j^i = w_{ij} u_i^i = w_{ij} y_i^i \quad j = 1, 2, \dots, |s| \quad (4)$$

当算得当前迭代轮次中所有食谱  $i$  的相关  $u^i$  后, 我们可通过式(5)得到第  $t$  轮次对  $y^t$  的平滑结果  $U^t$ :

$$U^t = \sum u^i \quad (5)$$

最后基于式(6)更新偏好度向量  $P$ , 其中  $\lambda$  是超参数, 类似于梯度下降法中的学习率, 然后对  $P_t$  进行正则化。

$$P_t = P_{t-1} + \lambda U^t \quad (6)$$

将  $S_{\text{all}}$  中与  $S_t$  中元素足够接近的所有元素加入  $B_t$ , 更新  $B_t$ 。

算法 1 中的 select 函数, 根据目前已经得到的食谱集合  $B_t$ 、当前饮食偏好度分布向量  $P_t$ , 从  $S_{\text{all}}$  中选择  $k$  个元素作为第  $t+1$  次迭代时呈现给用户的食谱集  $S_{t+1}$ , 参考多臂赌博机<sup>[11]</sup> 中的勘探和开发平衡问题, 从选择下一次需要呈现给用户的代表性食谱的时候, 需要平衡好已被选择 (包括足够接近) 的元素集合  $B_t$  和未被选择的元素集  $S_{\text{all}} \setminus B_t$  的关系。本文以一种比较简单的方式构造  $S_{t+1}$ , 先从  $B_t$  中以比例  $\omega$  选择  $\omega \times k$  个食谱, 再从  $S_{\text{all}} \setminus B_t$  中选择  $(1 - \omega) \times k$  个食谱, 共同构造  $S_{t+1}$ 。

在第一次为用户选代表性食谱结合  $S_1$  供用户选择的时候, 采取聚类的方式, 将  $S_{\text{all}}$  中所有食谱进行 Kmeans 聚类, 之后从聚类所得的  $k$  个类簇中, 采用每个类簇随机抽取 1 个食谱的形式为用户返回  $k$  个代表性食谱。ShowToUser( $S_t$ ) 向用户展示待选择的食谱集合  $S_t$ , 同时通过  $L_t \leftarrow \text{WaitForSelection}()$  获取用户的防窥。Android 客户端向用户展示待选择食谱集合  $S_t$ , 显示的字段包括菜谱名称、菜谱图像、口味、工艺、菜系多个模态的信息。

## 1.2 多维度食谱信息语义向量的表示学习

算法 MCS4FPR 所采用的食谱多模态信息对应的语义向量化方法如图 2 所示。食谱数据包括食谱图像、文本标题、烹饪说明文本、口味等信息。食谱维度信息的语义向量表示学习可借鉴现有方法。文献[7]中为食谱跨模态检索任务构建的食谱图像与食谱烹饪说明文本联合语义嵌入模型。采用 LSTM 等序列模型对食谱烹饪说明文本进行建模并获得特征向量, 用 ResNet50 作为基本模型对食谱图像进行特征向量抽取。模型随后通过全连接层将模型左右两部分信息连接在一起构成余弦相似度损失。模型还加入了语义正则化的步骤具体细节参见文献[5]。

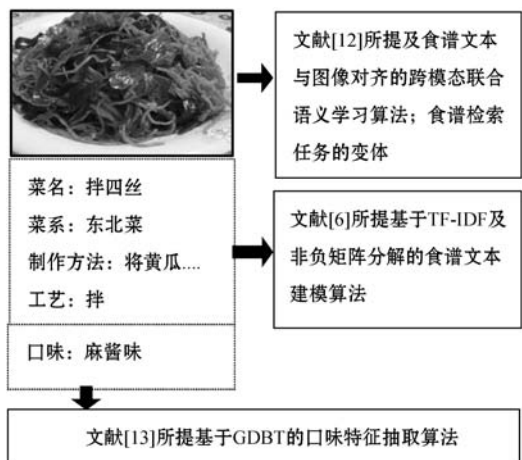


图2 食谱多模态信息及对应语义向量化方法

借鉴文献[14]中通过GBDT(梯度提升决策树)构造分类任务进行食谱口味语义向量学习的方法,对菜系、工艺进行GBDT特征构造。基于GBDT对特征进行自动离散化比直接平均离散化或者基于某些人工规则进行离散化更加合理,自动特征离散化能够增强模型使用特征时的鲁棒性。

文献[14]中将原始的调料成分特征作为GBDT的输入,口味属性作为label训练模型,获得构造的GBDT自动离散化向量,如图3所示。同理,我们在算法MCS4FPR中将烹饪工艺属性作为label,将制作过程的文本进行TF-IDF(词频-逆向文件频率)特征向量化后作为GBDT特征输入,学习GBDT特征。将菜系属性作为label,将食谱特点描述文本TF-IDF特征向量化后作为GBDT输入,学习GBDT特征。

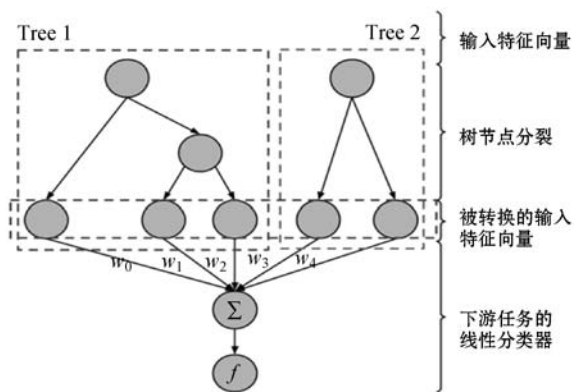


图3 GBDT特征构造过程

### 1.3 用户自定义的加权语义相似度计算

每个用户对食谱图像、口味、菜系、工艺关注度不同,因此,在冷启动阶段通过让用户选择评分条的方式获取用户自定义的对不同维度信息的关注度,并作为后续冷启动过程中食谱不同维度语义向量相似度合并时的计算权重。

获得用户对各维度评分之后,比如说视觉、口味、菜系、工艺分别是5星、5星、1星、2星,可通过式(7)

进行归一化:

$$R_i = \frac{r_i}{\sum_k r_k} \quad (7)$$

update()函数需要计算食谱之间的加权语义相似度,如果食谱的视觉、口味、菜系、工艺特征向量分别是 $\{f_1, f_2, f_3, f_4\}$ ,对应的正则化权重分别为 $\{R_1, R_2, R_3, R_4\}$ ,则食谱A和食谱B之间的加权语义相似度计算如下:

$$\text{similar}(r_{\text{recipe}_A}, r_{\text{recipe}_B}) = \sum_i R_i \times \cos(f_{A_i}, f_{B_i}) \quad (8)$$

## 2 实验结果与分析

(1) 线下阶段。我们实现了对食谱各维度信息的语义向量表示学习。图4是文献[7]的联合语义对齐模型在Chinese Diet Dataset(结构化的中餐食谱数据集,主要来自各大中文美食网站)数据集上进行微调后的效果。图4中的数字代表食谱之间的语义向量距离,我们可以看到每行两个相似食谱之间的语义距离都较小,每列三个不相似食谱之间的语义距离都较大,符合人的直觉,说明我们对食谱视觉信息进行了有效的语义向量化。




图4 食谱视觉信息语义向量化语义距离实例

借鉴文献[14]将原始的调料成分特征作为GBDT的输入,口味属性作为label训练模型,获得构造的GBDT自动离散化向量。这里将烹饪工艺属性作为label,将制作过程的文本进行TF-IDF特征向量化后作为GBDT特征输入,学习GBDT特征。将菜系属性作为label,将食谱特点描述文本TF-IDF特征向量化后作为GBDT输入,学习GBDT特征。

从表1可以发现,“洋烧排骨”和其top5口味相似

食谱的名称基本上都带有“烧”或“醋”字,可能是因为烹饪工艺类似,因此口味相似,都是酸甜味,表明口味语义向量表示学习的有效性。

表 1 GBDT 构造的与“洋烧排骨”最相似食谱口味语义向量

食谱名称	口味	食谱口味语义向量相似度
洋烧排骨	酸甜味	1.000 0
葱烤鲫鱼	酸甜味	0.981 6
炒醋鱼块	酸甜味	0.975 2
脆皮炸大肠	酸甜味	0.971 2
红烧荷包蛋	酸甜味	0.961 2
糖醋莲排	酸甜味	0.959 8

从表 2 可以发现,不仅“洋烧排骨”的 top5 菜系相似食谱都是福建菜,进一步的 top3 食谱中都采用了“烧”的烹饪工艺,说明捕获了更细致的菜系维度信息。

表 2 GBDT 构造的与“洋烧排骨”最相似食谱菜系语义向量

食谱名称	菜系	食谱菜系语义向量相似度
洋烧排骨	福建菜	1.000 0
红烧猪蹄	福建菜	0.985 6
锅烧鸭	福建菜	0.977 8
楚乡鸡	福建菜	0.964 2
白切鸡	福建菜	0.961 7
金陵片皮鸭	福建菜	0.958 6

(2) 线上阶段。邀请志愿者参与评估,构成如下:邀请 10~20 岁、20~30 岁、30~40 岁、40~50 岁、50~60 岁 5 个年龄段的志愿者各 10 位,共 50 位志愿者对不同算法进行评测。为了排除性别因素干扰,各个年龄段志愿者男女比例均为 1:1。为了方便对比各冷启动算法的效果,所选择志愿者均没有明显的挑食习惯,也不患有需要进行饮食限制的疾病。

用户可在经过不同算法的冷启动过程后,通过本 Android 客户端对算法推荐的 topN (用户偏好度最大的  $N$  个食谱) 食谱进行评测。本实验记录不同总迭代轮次  $T$  下,为用户  $j$  推荐的 topN 食谱中符合用户饮食偏好的食谱的数量  $K_j$ , 计算  $k/N$  作为每个用户在当前算法下的 topN 准确率  $Acc$ , 最后对共  $M$  位用户的 topN  $Acc$  求平均, 得到饮食偏好宏平均准确率  $MacroAcc$  作为算法效果指标,  $MacroAcc$  越高代表算法效果越好。计算方式如式(9)所示。

$$MacroAcc = \frac{\sum_i^M \sum_j^N \frac{K_j}{N}}{M} \quad (9)$$

如图 5 所示,不同饮食推荐冷启动算法对比,横坐标是迭代的次数,纵坐标是准确率。不同总迭代轮次  $T$  ( $T=5,10,15$ ), 为用户推荐 top50 食谱,不同算法的 top50  $MacroAcc$ 。

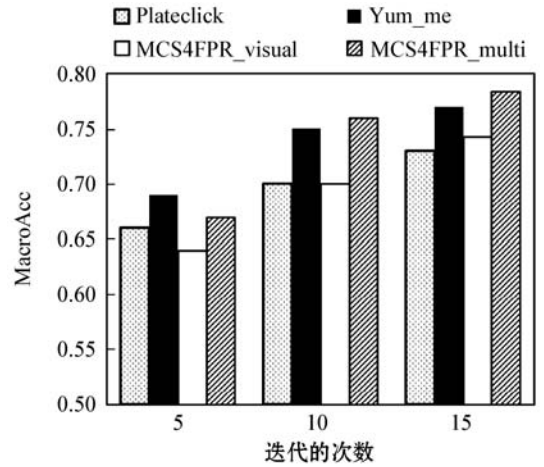


图 5 饮食推荐冷启动算法对比

随着迭代轮次的增加,不同算法的预测准确率均得到了提升,这是因为在算法迭代过程中捕获了用户的饮食偏好信息。迭代轮次为 15 时,仅采用视觉信息 (MCS4FPR\_visual) 预测准确率为 74.3%, 明显低于 MCS4FPR\_multi (78.4%), 可见食谱多维度信息的融合对于饮食偏好推荐的重要性。仅采用视觉信息的 MCS4FPR\_visual (74.3%) 比同样仅采用视觉信息的 Yum\_me (77%)<sup>[15]</sup> 的效果差,但是采用多维度食谱信息的 MCS4FPR\_multi (78.4%) 则超过 Yum\_me, 进一步说明了食谱多维度信息的结合对于食谱推荐的重要性。

如图 6 所示,横坐标是饮食冷启动不同的算法。其中:our\_visual 是 MCS4FPR\_visual;our\_multi 是 MCS4FPR\_multi。经过 15 次迭代后,各模型为不同性别志愿者推荐的准确率,即将上述 50 位志愿者在迭代 15 次后的 50 例评估结果分别分为男性组和女性组,各占 25 个数据,然后计算 topN 宏平均准确率。可以看出不同算法对男性和女性的预测准确率没有明显差异。

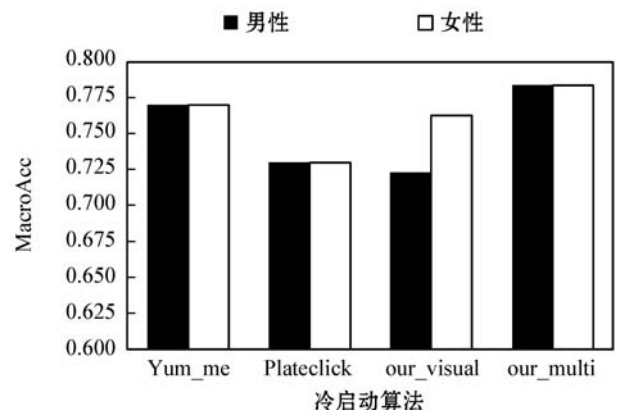


图 6 饮食推荐冷启动算法不同性别下准确率

如图7所示,迭代15次后的50例评估结果分别分为10~20岁组、20~30岁组、30~40岁组、40~50岁组、50~60岁组,每组各占10个数据(男性5例,女性5例)。各算法对性别因素不敏感,因此每个年龄组不进一步区分性别。对各年龄组计算topN宏平均准确率。结果显示各算法的topN MacroAcc受年龄因素影响明显,且受影响结果相似,为了避免累赘,这里只展示MCS4FPR\_multi不同年龄段下的预测准确率。可以看出算法对20~30岁组预测的topN MacroAcc值最高,之后随着年龄的增加,topN MacroAcc逐渐下降,这可能是因为随着年龄的不同,工作压力、身体状态等不同,进而导致了食欲不同。




图7 MCS4FPR\_multi不同年龄段下准确率

### 3 结语

本文提出一种基于多模态的冷启动饮食推荐算法,与现有饮食推荐方法仅基于视觉信号进行冷启动不同,本文方法考虑了食谱丰富的多模态信息,主要包括食谱图像、文本等信息,同时考虑了不同用户对食谱各维度信息关注度的不同。本文算法分线上线下两阶段。线下阶段,本文算法通过多种语义向量表示学习算法,获得食谱不同维度信息的语义向量。在线上阶段,首先通过获取用户对食谱各维度信息的自定义关注度计算加权的多模态食谱语义向量相似度。然后通过饮食偏好度迭代传播算法,算出用户对所有食谱的偏好度排序列表,进而进行推荐。

由于目前没有开源的数据集可用于饮食偏好冷启动算法的评估,我们开发了Android客户端来为用户呈现食谱丰富的多模态信息,保证用户反馈结果的可靠性,让实验结果更有说服力。

基于食谱多模态信息的冷启动算法MCS4FPR,通过线性加权的方式将食谱不同维度的信息融合进冷启动算法中,而不同食谱维度信息之间的关系不一定是简单的线性关系,还应该探索更多的融合方法。

### 参 考 文 献

- [1] Harvey M, Ludwig B, Elswailer D. You are what you eat: Learning user tastes for rating prediction[C]//20th International Symposium on String Processing and Information Retrieval,2013:153-164.
- [2] Elswailer D, Trattner C, Harvey M. Exploiting food choice biases for healthier recipe recommendation[C]//40th International ACM SIGIR Conference on Research and Development in Information Retrieval,2017:575-584.
- [3] Trattner C, Elswailer D. Food recommender systems: Important contributions, challenges and future research directions[EB]. arXiv:1711.02760,2017.
- [4] Ge M, Elahi M, Fernández-Tobías I, et al. Using tags and latent factors in a food recommender system[C]//5th International Conference on Digital Health,2015:105-112.
- [5] Yang L, Hsieh C, Yang H, et al. Yum-Me: A personalized nutrient-based meal recommender system[J]. ACM Transactions on Information Systems,2017,36(1):1-31.
- [6] Yang L, Cui Y, Zhang F, et al. Plate-click: Bootstrapping food preferences through an adaptive visual interface[C]//24th ACM International on Conference on Information and Knowledge Management,2015:183-192.
- [7] Marín J, Biswas A, Ofli F, et al. Recipe1M+: A dataset for learning cross-modal embeddings for cooking recipes and food images[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2021,43(1):187-203.
- [8] Min W, Jiang S, Jain R. Food recommendation: Framework, existing solutions and challenges[J]. IEEE Transactions on Multimedia,2019,22(10):2659-2671.
- [9] Forbes P, Zhu M. Content-boosted matrix factorization for recommender systems: Experiments with recipe recommendation[C]//ACM Conference on Recommender Systems,2011:261-264.
- [10] Zhou D, Bousquet O, Lal T, et al. Learning with local and global consistency[C]//16th International Conference on Neural Information Processing Systems,2003:321-328.
- [11] Auer P, Cesa-Bianchi N, Freund Y, et al. The nonstochastic multiarmed bandit problem[J]. SIAM Journal on Computing,2003,32(1):48-77.
- [12] Fitzmaurice C, Allen C, Barber R. A systematic analysis for the global burden of disease study[J]. JAMA Oncol,2017,3(4):524-548.
- [13] 曹莹,苗启广,刘家辰,等. AdaBoost 算法研究进展与展望[J]. 自动化学报,2013,39(6):745-758.
- [14] 喻兵,郝梓杰,罗裕升,等. 基于多维度特征的饮食健康推荐[J]. 计算机应用与软件,2019,36(7):110-116.
- [15] Atlas D. International diabetes federation[EB/OL]. [2021-03-06]. <https://diabetesatlas.org/atlas/seventh-edition/>.