

面向时序感知的多类别商品方面情感分析推荐模型

丁永刚^{①②} 李石君^{*①} 付星^③ 刘梦君^②

^①(武汉大学计算机学院 武汉 430072)

^②(湖北大学教育学院 武汉 430062)

^③(湖北大学数学与统计学学院 武汉 430062)

摘要: 电子商务网站中的评论数据隐含着商品特征和用户情感, 现有基于方面情感分析的推荐研究大多通过抽取同一类别商品评论数据中用户对商品不同方面的情感来捕捉用户方面偏好, 忽略了不同类别商品有不同方面以及用户的方面偏好随时间变化的特点。对此, 该文提出一种面向时序感知的多类别商品方面情感分析推荐模型, 该模型对用户、商品类别、商品、商品方面、方面情感和时间统一建模, 以发现用户对不同类别商品的方面偏好随时间变化的特点, 并据此做出推荐。该模型能够推断用户在任意时间对商品的方面偏好, 从而为用户提供可解释的推荐。两个真实数据集的实验结果表明, 与其它基于时间或方面情感分析的推荐模型相比, 该文提出的模型在 top-*N* 推荐准确率和召回率评价指标上均获得显著改善。

关键词: 推荐; 时序感知; 多类别; 方面情感分析; 概率潜在语义分析

中图分类号: TP393

文献标识码: A

文章编号: 1009-5896(2018)06-1453-08

DOI: 10.11999/JEIT170938

Temporal-aware Multi-category Products Recommendation Model Based on Aspect-level Sentiment Analysis

DING Yonggang^{①②} LI Shijun^① FU Xing^③ LIU Mengjun^②

^①(School of Education, Hubei University, Wuhan 430072, China)

^②(School of Computer Science, Wuhan University Wuhan 430062, China)

^③(Faculty of Mathematics and Statistics, Hubei University, Wuhan 430062, China)

Abstract: Review data in e-commerce websites implicates items' features and users' sentiment. Most existing recommendation researches based on aspect-level sentiment analysis capture users' aspect preference for items by extracting users' sentiment towards different aspects of items in the review data of a same category, ignoring that different category items have different aspects and that users' aspect preference varies by time. A temporal-aware multi-category products recommendation model is proposed based on aspect-level sentiment analysis, which jointly models user, category, item, aspect, aspect-sentiment and time in order to find how users' aspect preferences vary by time on different category items. This model is able to infer users' aspect preferences for items at any time, which can provide users with explainable recommendations. Experiment results on two real-world data sets show that, in comparison to other recommendation models based on time or aspect-level sentiment analysis, the proposed model achieves significant improvement in the precision and recall for the top-*N* recommendation.

Key words: Recommendation; Temporal-aware; Multi-category; Aspect-level sentiment analysis; Probabilistic Latent Semantic Analysis (PLSA)

1 引言

随着在线用户的迅速增加, 电子商务网站的评

论数据呈爆炸式增长。由于评论数据中隐含着用户对商品是否满意的情感信息, 因此推荐算法逐渐从单纯地利用用户评分发展到通过分析用户在评论中表达的情感来做出推荐。早期基于情感分析的推荐通常基于文档级或句子级情感分析方法, 为评论预测一个情感极性或总评分来做出推荐^[1,2]。然而, 这两种情感分析方法只能揭示用户在评论中所表达的对商品是否满意的总体偏好, 而不能反映用户对商

收稿日期: 2017-10-11; 改回日期: 2018-04-17; 网络出版: 2018-05-03

*通信作者: 李石君 shjli@whu.edu.cn

基金项目: 国家自然科学基金(61502350), 国家自然科学基金联合基金(U1536114)

Foundation Items: The National Natural Science Foundation of China (61502350), The Joint Funds of National Natural Science foundation of China (U1536114)

品不同方面是否满意的详细偏好。这使得基于方面情感分析^[3]进行推荐逐渐成为一个新的研究热点。

基于方面情感分析的推荐方法大致分为3类：一是利用有监督学习方法^[4,5]来推断方面权重和方面评分，然后使用多指标协同过滤算法做出推荐^[6]；二是通过构建情感词典^[7]或利用无监督学习方法^[8]从评论中抽取方面-情感词对，并将其集成到矩阵分解或张量-矩阵分解模型来做出推荐^[9,10]；三是利用概率模型对方面、情感和方面评分进行统一建模来做出推荐^[11,12]。这些方法能够通过挖掘评论中隐含的商品方面和方面情感来捕捉用户的详细偏好，但它们都是以静态的方式抽取商品方面和预测其情感，忽略了用户方面偏好随时间变化的特点。

为了捕捉用户方面偏好随时间变化的规律，文献^[13-15]基于整个评论集文本研究了群体用户的方面情感随时间变化的规律，但他们的方法不能揭示每个用户的方面情感随时间变化的特点。另一方面，基于时间的推荐算法也得到研究^[16-20]，这些方法通过在传统的矩阵分解、张量分解或主题模型中加入时间因子来考虑时间因素对用户偏好的影响，使得推荐性能在一定程度上有所提升，但它们没有考虑评论文本中隐含的用户方面偏好信息，因此，其性能提升仍然受到一定限制。此外，除文献^[10]外，大多基于方面情感分析的推荐方法只适用于包含同一类别商品的评论文本，但实际获得的评论语料往往包含多种类别的商品评论数据，而用户对不同的商品类别有不同的方面偏好，因此，这些方法在数据集包含多种商品评论数据的情况下无法捕捉用户的方面偏好。

鉴于此，本文提出一个面向时序感知的多类别商品方面情感分析推荐模型，该模型同时捕捉商品类别、商品方面和方面情感3个隐因子变量和时间之间的依赖关系，以发现用户对不同类别商品的方面情感随时间变化的规律，从而提高推荐的准确度。本文的主要贡献如下：

(1)提出一种基于概率潜在语义分析(PLSA)挖掘用户在多种类别商品上的方面情感随时间变化的偏好模型，称为类别-方面-情感-时间模型(TMCAS)。该模型通过建模商品类别、商品方面和方面情感与时间之间的交互关系来发现用户方面偏好随时间的变化规律。

(2)利用两级EM推断算法估计模型参数，并提出面向时间的商品推荐和用户推荐算法，给出推荐理由。

(3)在真实数据集上进行实验，对模型的推荐效果进行评估。实验结果表明，该模型在面向时间的

商品推荐和用户推荐准确度方面，比其他相关模型均有显著改善。

2 面向时序感知的多类别商品方面情感推荐模型

2.1 动机与直觉

为了构建时序感知的多类别商品方面情感分析推荐模型，我们首先给出如下动机与直觉：

直觉 1 一个用户决定是否购买某种类别的商品，是基于他对该类别商品的兴趣和一个合适的购买时间。比如，一个用户决定购买一款苹果手机，是因为他对苹果手机感兴趣，但他同时可能需要考虑在一个合适的时间购买(如在手机打折或经济比较宽裕的时间购买)。

直觉 2 一个用户决定是否购买某个商品，是基于用户对该商品的某些方面感到满意。比如，一个用户决定购买一款苹果手机，是因为他对该款苹果手机的内存大小、价格等方面感到满意。对于不同类别的商品，用户有不同的兴趣方面；而对于同种类别的商品，不同用户也有不同的兴趣方面。如一些用户可能关注手机的内存大小，而另一些用户则可能关注手机的价格范围。

直觉 3 一个用户对某个商品给出较高评分，是因为他对该商品的某些方面比较满意。当一个用户为某个商品撰写评论时，用户的这种偏好会在评论文本中反映出来，他会使用商品方面词和表达对该方面是否满意的情感词，同时，用户提交评论时系统会提供一个相应的时间戳。如某用户撰写的评论可能是：“iphone 7 苹果手机价格很贵，但内存很大”。这里评论者使用“价格”、“内存”表示方面，使用“很贵”、“很大”来表达情感，同时系统提供一个时间戳 2015-7-25。

2.2 模型建立

假设 D 是用户评论集合， D 中的每条评论 $d \in D$ 由 M 个句子组成，而每个句子由 N 个单词组成； U 是用户集合； I 是商品集合；商品种类、商品方面、方面情感和时间分别用 c, a, s 和 t 表示，则本文所使用的记号如表 1 所示。这样，一条评论 d 可以表示成一个 4 元组 $d = \{u_d, i_d, w_d, t_d\}$ ，这里 u_d 表示评论者， i_d 表示评论的商品， t_d 表示撰写评论 d 的时间， w_d 表示评论 d 中的单词。基于以上直觉，建立 TMCAS 模型如下：

(1)对于给定用户的每条评论 $d \in D_u$ ，用户首先基于多项式分布 $p(c|u)$ 选择其感兴趣的商品类别，然后基于高斯分布 $p(t|u)$ 选择一个合适的购买时间，这样，用户购买商品的概率可以定义为 $p(i|c)$

表 1 记号描述

记号	描述
u, U	用户和用户集合
i, I	商品和商品集合
c	商品类别
t	时间
a, s	方面和情感
d, D	评论和评论集合
M	一条评论中句子的数量
w, N	一个句子中的单词和单词的数量

$p(i|t)$ 。这里 $p(i|c)$ 是用户选择购买类别 c 中商品 i 的概率， $p(i|t)$ 是用户在时间 t 购买商品 i 的概率。

正则化后得到定义 $p(i|c, t) = \frac{p(i|c)p(i|t)}{\sum_{i'} p(i'|c)p(i'|t)}$ 。我

们把用户在时间 t 购买商品 i 的概率 $p(i|t)$ 建模为均匀分布，而把购买类别 c 中商品 i 的概率 $p(i|c)$ 建模为高斯分布(直觉 1)。

(2)用户对不同类别的商品有不同的兴趣方面，因此建模用户对某类商品的方面偏好 $p(a|u, c)$ 为多项式分布，同时，用户对于不同的商品方面有不同的情感，因此，将商品的方面情感 $p(s|a, i)$ 也建模为多项式分布(直觉 2)。

(3)基于生成的方面和情感，建模商品类别、商品方面、方面情感和评论词之间的关系为 $p(w|a, s, c) = \lambda p(w|a, s) + (1-\lambda)p(w|c)$ ，其中， a, s, c 分别表示方面、情感和商品类别。 $p(w|a, s)$ 是用户对方面 a 具有情感 s 时使用单词 w 的概率， $p(w|c)$ 是用户使用单词 w 描述商品类别 c 的概率，参数 λ 用来平衡从方面、情感或商品类别抽取单词的比例。这里对 $p(w|a, s)$ 建模而不对 $p(w|a)$ 和 $p(w|s)$ 建模是因为方面和情感总是相关的，而且建模 $p(w|a, s)$ 可以估计较少的参数。同时，这里假设每个句子只表达商品的一个方面，而每个方面只与一种情感(肯定、否定或中立)相联系(直觉 3)。

综上所述，TMCAS 模型表示如图 1 所示。用户 u 生成评论的过程如下：

对于每条评论 $d \in D_u$ (这里 D_u 是用户 u 的评论集合)：

- (1)抽取用户时间偏好 $t \sim p(t|u)$;
- (2)抽取用户类别偏好 $c \sim p(c|u)$;
- (3)抽取用户购买偏好 $i \sim p(i|c, t) =$

$\frac{p(i|c)p(i|t)}{\sum_{i'} p(i'|c)p(i'|t)}$ ，其中 $p(i|t)$ 为均匀分布， $p(i|c) \sim N(\mu_c, \sigma_c)$ 为高斯分布。




图 1 类别-方面-情感-时间模型(TMCAS)

对于评论 d 中的每个句子：

(1)抽取方面 $a \sim p(a|u, c)$;

(2)抽取情感 $s \sim p(s|a, i)$ 。

对于句子中的每个单词：抽取单词 $w \sim$

$$p(w|a, s, c) = \lambda p(w|a, s) + (1-\lambda)p(w|c)。$$

模型中的 $p(t|u)$, $p(i|t)$ 可以从给定的语料中直接估计，而其它参数需要推断。

2.3 模型参数估计

(1)似然函数计算：TMCAS 模型有 3 个级别，即文档级、句子级和词组级，而潜在变量在两个级别上，即商品类别 c 在文档级别，方面 a 和情感 s 在句子级。对这种多级结构似然函数参数估计，需要使用两步 EM 算法。如图 1 所示，根据生成过程，可以得到评论集 D 在句子级的似然函数为

$$p(D; \Psi) = \prod_d p(u_d) p(t_d|u_d) \sum_c p(c|u_d) \cdot p(i_d|c, t_d) p(w_d|u_d, i_d, c) \quad (1)$$

$$p(w_d|u_d, i_d, c) = \prod_k p(w_{d_k}|u_d, i_d, c) \quad (2)$$

$$p(w_{d_k}|u_d, i_d, c) = \sum_{a, s} p(a|u_d, c) p(s|a, i_d) \cdot p(w_{d_k}|a, s, c) \quad (3)$$

$$p(w_{d_k}|a, s, c) = \prod_{w \in d_k} p(w|a, s, c)^{n(w, d_k)} \quad (4)$$

$$p(w|a, s, c) = \lambda p(w|a, s) + (1-\lambda)p(w|c) \quad (5)$$

式(1)中， Ψ 为模型参数集，即 $\Psi = \{p(c|u), \mu_c, \sigma_c, p(a|u, c), p(s|a, i), p(w|a, s), p(w|c)\}$ 。变量 u_d, i_d, w_d, t_d 分别表示评论 d 的用户，商品，单词集和时间。向量 w_{d_k} 表示评论 d 的第 k 个句子的单词集合， $n(w, d_k)$ 是单词 w 在评论 d 的第 k 个句子中的数量。

对似然函数 $p(D; \Psi)$ 取对数，得到式(6)：

$$\begin{aligned} \lg p(D; \Psi) = & \sum_d \lg p(u_d) + \sum_d \lg p(t_d|u_d) \\ & + \sum_d \lg \sum_c p(c|u_d) p(i_d|c, t_d) \\ & \cdot p(w_d|u_d, i_d, c) \end{aligned} \quad (6)$$

(2)期望值最大化估计: 采用期望最大化算法(EM)对模型参数估计如下:

E-Step: 根据可观察的数据, 计算隐含变量的数学期望。对式(6)使用 Jensen 不等式, 得到似然函数下界为

$$L_{LB} = \sum_d \lg p(u_d) + \sum_d \lg p(t_d | u_d) + \sum_{d,c} p(c|d) (\lg p(c|u_d) + \lg p(i_d | c, t_d) + \lg p(\mathbf{w}_d | u_d, i_d, c)) \quad (7)$$

$$p(c|d) = \frac{p(c,d)}{\sum_{c'} p(c',d)} \quad (8)$$

M-Step: 利用拉格朗日乘数法可得到使 L_{LB} 在约束条件 $\sum_c p(c|u_d)=1$ 下取极值时, 参数 $p(c|u)$ 的修正函数为

$$p(c|u) = \frac{\sum_{d \in D_u} p(c|d)}{\sum_{c'} \sum_{d \in D_u} p(c'|d)} \quad (9)$$

式(9)中由于存在正则项, 得不到 μ_c, σ_c 的闭合解, 因此采用梯度方法来得到修正的 μ_c, σ_c 值。具体地, 采用 BFGS 拟牛顿法, 计算 μ_c, σ_c 的梯度为

$$\frac{\partial L_{LB}}{\partial \mu_c} = \sum_d p(c|d) \left\{ i_d - \mu_c - \frac{\sum_{i'} (i'_d - \mu_c) q(i')}{\sum_{i'} q(i')} \right\} \quad (10)$$

$$\frac{\partial L_{LB}}{\partial \sigma_c} = \sum_d p(c|d) \left\{ \frac{(i_d - \mu_c)^2}{\sigma_c^3} - \sum_{i'} q(i') \frac{(i'_d - \mu_c)^2}{\sigma_c^3} \right\} \quad (11)$$

$$q(i') = p(i' | c) p(i' | t) \quad (12)$$

由于方面和情感处于句子级别, 不能使用 $p(c|u)$ 通过式(7)来计算 $\lg p(\mathbf{w}_d | u_d, i_d, c)$, 因此这里使用 2 级 EM 迭代算法, 即通过引入一个新的潜在变量来估计与方面和情感相关的参数。这里用 ϕ_{a,s,c,d_k} 来表示评论 d 的第 k 个句子描述种类 c 的方面 a 具有情感 s , 并记 $\phi_{a,s,c,d_k} = p(a, s | c, d_k)$, 这样, 可使用 ϕ_{a,s,c,d_k} 和 $p(c|u)$ 来计算参数 $p(a|u, c)$, $p(s|a, i)$, $p(w|a, s)$, $p(w|c)$ 的修正函数。

句子级似然函数为

$$p(D; \Phi) = \prod_{d \in D_u} \prod_k \sum_c p(c, d_k) = \prod_{d \in D_u} \prod_k \sum_c \sum_{a,s} p(a, s, c, d_k) \quad (13)$$

对式(12)使用 Jensen 不等式, 得到似然函数的

下界为

$$\begin{aligned} \tilde{L}_{LB} &= \lg p(D; \Phi) = \sum_d \sum_k \lg \left(\sum_c \sum_{a,s} \lg p(a, s, c, d_k) \right) \\ &\geq \sum_d \sum_k \lg \left(\sum_c p(c | d_k) \cdot \sum_{a,s} p(a, s | c, d_k) p(a, s, c, d_k) \right) \\ &\geq \sum_d \sum_k \sum_c p(c | d_k) \sum_{a,s} \phi_{a,s,c,d_k} \lg p(a, s, c, d_k) \quad (14) \\ p(a, s, c, d_k) &= p(u_d) p(c | u_d) p(t_d | u_d) p(i_d | t_d, c) \\ &\quad \cdot p(a | u_d, c) p(s | a, i_d) \\ &\quad \cdot \prod_{w \in d_k} p(w | a, s, c)^{n(w, d_k)} \quad (15) \end{aligned}$$

其中, $n(w, d_k)$ 表示评论 d 的第 k 个句子中单词 w 出现的个数。

类似地, 利用拉格朗日乘数法, 通过最大化似然函数的下限, 可以得到其余参数的修正函数。

$$p(a | u, c) = \frac{\sum_{d \in D_u} p(c | d) \sum_k \sum_s \phi_{a,s,c,d_k}}{\sum_{a'} \sum_{d \in D_u} p(c | d) \sum_k \sum_s \phi_{a',s,c,d_k}} \quad (16)$$

$$p(s | a, i) = \frac{\sum_{d \in D_i} \sum_c p(c | d) \sum_k \phi_{a,s,c,d_k}}{\sum_{s'} \sum_{d \in D_i} \sum_c p(c | d) \sum_k \phi_{a,s',c,d_k}} \quad (17)$$

$$p(w | a, s) = \frac{\sum_{d \in D_u} \sum_c p(c | d) \sum_k \phi_{a,s,c,d_k} n(w, d_k)}{\sum_{w'} \sum_{d \in D_u} \sum_c p(c | d) \sum_k \phi_{a,s,c,d_k} n(w', d_k)} \quad (18)$$

$$p(w | c) = \frac{\sum_{d \in D_u} p(c | d) \sum_{a,s} \sum_k \phi_{a,s,c,d_k} n(w, d_k)}{\sum_{w'} \sum_{d \in D_u} p(c | d) \sum_k \phi_{a,s,c,d_k} n(w', d_k)} \quad (19)$$

其中, D_u 是用户 u 撰写的评论集合, D_i 是商品 i 的评论集合。

3 模型应用

3.1 面向时间的商品推荐

(1)多类别推荐: 多类别推荐是在给定时间 t 的情况下, 为用户 u 生成所有类别商品的一个排行榜。通过计算 $p(i, s_{\pm} | u, t)$ 的概率, 即通过计算用户 u 在时间 t 对于商品 i 具有积极情感的概率来为商品打分。

$$p(i, s_{\pm} | u, t) = \sum_c p(c | u) p(i | c, t) \cdot \sum_a p(a | u, c) p(s_{\pm} | a, i) \quad (20)$$

根据式(20), 通过匹配用户偏好(即 $p(c_i | u)$ 和 $p(a | u, c_i)$)和商品属性(即 $p(i | c_i, t)$ 和 $p(s_{\pm} | a, i)$)来

做出推荐。这个模型能够解释为用户推荐商品的原因。首先根据 $p(s_+ | a, i)$ $p(a | u, c_i)$ 计算用户对商品的方面情感并进行评分排序, 以揭示商品的哪些方面更匹配用户的偏好, 然后根据 $p(c_i | u)$ $p(i | c_i, t)$ 计算商品类别在时间 t 的排序, 以揭示哪种类别的商品在时间 t 更被用户喜欢。最后, 我们选择 top- N 的类别和方面在时间 t 做出可解释的推荐。

(2)单类别推荐: 单类别推荐是在给定时间 t 和类别 c 的情况下, 为用户 u 生成类别 c 的商品排行榜。与多类别推荐不同, 单类别推荐固定了类别 c , 即从式(20)中移除了 $p(c | u)$, 所有不在类别 c 中的商品都不在推荐之列。单类别推荐公式如式(21)所示。据此, 同样可以按照多类别推荐的方法, 对单类别推荐做出解释。

$$p(i, s_+ | u, t, c) = p(i | c, t) \sum_a p(a | u, c) p(s_+ | a, i) \quad (21)$$

3.2 面向时间的用户推荐

模型也可以为商品推荐用户。给定时间 t 和商品 i , 可以考虑类别和方面来计算用户 u 喜欢商品 i 的概率 $p(u, s_+ | i, t)$, 如式(22)所示。

$$p(u, s_+ | i, t) = \frac{p(u, s_+, i, t)}{\sum_{u, s} p(u, s, i, t)} \quad (22)$$

$$p(u, s, i, t) = p(u) p(t | u) \sum_c p(c_i | u) p(i | c_i, t) \cdot \sum_a p(a | u, c_i) p(s | a, i) \quad (23)$$

其中, 先验概率 $p(u)$ 通过用户的历史评论记录来计算:

$$p(u) = N_u / N \quad (24)$$

这里, N_u 为用户 u 所写评论数, N 为总的评论数。

4 实验和结果

4.1 实验设计

4.1.1 数据集描述 实验选取 Amazon 和 Tripadvisor 评论数据作为实验数据。Amazon 数据集中包含 24 种不同类别的产品评论数据, 我们选取包含图书、相机、手机、手提电脑等 6 种类别的商品评论作为实验数据; Tripadvisor 数据集包含数 10 种商务活动评论数据, 我们选取包含着酒店、餐馆、景点、航班等 6 种商务活动评论数据作为实验数据。数据集的统计情况如表 2 所示。

表 2 实验数据集统计情况

数据集	用户数	商品	评论数	平均每个用户评
Amazon	13695	15285	454852	33.21
Tripadvisor	14267	1850	261044	18.29

将每个用户的数据进行划分, 分别抽取 80%, 10%和 10%为训练集、验证集和测试集。在验证集和测试集中, 通过查看用户评分来确定一个用户是否喜欢一个产品, 当用户的评分大于 3 分时, 认为用户喜欢该产品, 则可以把用户-产品对放入真值集中。

4.1.2 评价指标 本实验使用准确率(Precision)和召回率(Recall)指标来评价模型的性能。对于 top- N 推荐, 实验评估 $N = 5$ 时的准确率和召回率。此外, 实验也使用平均准确率(Mean Average Precision, MAP)来评估推荐列表的准确性, 它是排序位置敏感的评价指标, 其值越大, 说明与用户偏好相关的物品排序越靠前, 排序效果越好。

4.1.3 对比方法 本实验选取以下模型与 TMCAS 模型进行比较, 其中 PMF 为基线模型, LRPPM 和 SUML 为基于方面情感分析的推荐模型, timeSVD++和 FTM 为基于时间的推荐模型。

(1)PMF^[21]: 基于概率矩阵分解的推荐模型, 该模型没有利用用户评论信息。

(2)LRPPM^[10]: 基于方面情感的张量分解排序模型, 通过将用户、商品和方面情感表示为一个 3 维张量来预测用户的方面特征偏好排序。该方法能够对多种类别商品的方面特征偏好进行预测。

(3)SUML^[13]: 基于方面情感的混合推荐模型, 它使用矩阵分解技术抽取最有价值的方面及其情感, 然后使用一个线性预测模型来对商品做出预测评分。

(4)timeSVD++^[17]: 基于 SVD++的推荐模型, 考虑了时间因素对用户偏好的影响。

(5)FTM^[20]: 基于用户动态偏好的混合推荐模型, 首先使用动态主题模型来建模用户动态行为, 然后将其与商品主题、用户历史偏好以及商品流行度一起集成到矩阵分解框架来预测用户的未来偏好。

4.2 实验结果

4.2.1 多类别商品推荐 实验选取从 2013-01-01 到 2014-04-01 之间的 7 个时间点进行实验。图 2 的实验结果表明, 与已有基于方面情感的最好模型 SUML 和基于时间的最好模型 FTM 相比, TMCAS 模型在 Amazon 和 Tripadvisor 数据集上所选 7 个时间点的 Precision@5, Recall@5 和 MAP 指标均有显著提高。显然, 这是由于 TMCAS 模型同时考虑了时间和方面情感对用户偏好的影响, 因此取得了最好的性能。由于 Amazon 数据集中的评论语料比 Tripadvisor 的评论语料多, 模型对用户方面偏好的捕捉更准确, 因而其预测的效果更好。

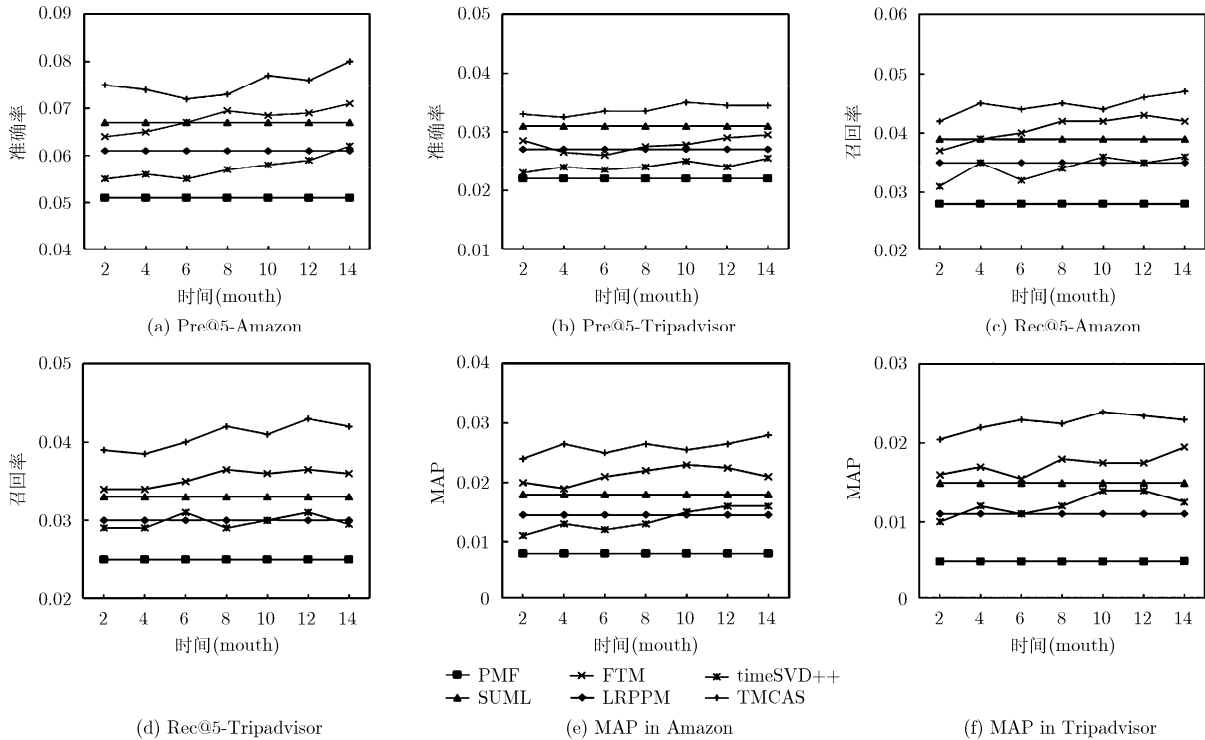


图 2 面向时间的多类别商品推荐

在基线方法中，LRPPM 和 SUML 模型由于考虑了评论中用户的方面情感来做出推荐，因此其性能均优于 PMF，而 LRPPM 同时还考虑了多种类别商品的方面特征，因此其性能好于 SUML。但是由于它们没有考虑时间因素对用户偏好的影响，因此其性能受到一定限制。而 timeSVD++ 和 FTM 模型考虑了时间因素对用户偏好的影响，因此其性能也均优于 PMF。但由于它们只考虑了时间因素对用户总体偏好的影响，而没有考虑时间因素对用户方面偏好的影响，因此其性能仍不及本文提出的 TMCAS 模型。

4.2.2 单类别商品推荐 如果用每个用户的购买历史记录来进行单类别商品推荐会遭遇数据稀疏问题，因此是实验从所有类别中指定一种类别来进行 top-N 推荐。由于 TMCAS 能够发现类别和方面之

间的关系，即 $p(a|c,u)$ ，因此其 Precision@5 和 Recall@5 与其他相关模型相比均有显著提高。鉴于篇幅原因，在此不再赘述。

4.2.3 推荐解释 为了说明 TMCAS 模型能够解释推荐商品的原因，在测试集中随机挑选一些样例，探测用户在时间 t 喜欢的商品类别和方面。为了找出哪个方面对推荐的贡献最大，可以通过计算 $p(a|u,c)$ 在类别 c 中为用户 u 挑选其最喜欢的 5 个方面，然后根据 $p(s_+|a,i)$ 计算用户 u 在时间 t 对商品 i 具有积极情感的前 5 个方面。图 3 表明了 Amazon 数据集上某用户的方面偏好和在时间 t 为其推荐的商品具有积极情感的 5 个方面。可以看出，二者的概率趋势是一致的。

4.2.4 用户推荐

(1) 对比方法和评价指标： FTM 是基于主题




图 3 某用户的方面偏好和在时间 t 被推荐商品的积极情感方面

模型的，将其预测评分乘以 $p(u)$ 以及条件概率 $p(i | u)$ 即可将其应用到用户推荐。然而，由于基线方法 PMF, LRPPM, SUML 和 timeSVD++ 都不适用于用户推荐。因此，对于 PMF，将用户和项目评分矩阵进行转置再应用模型的预测结果来进行用户推荐；对于 LRPPM, SUML 和 timeSVD++，可以基于 R_{ij} 为每个商品的 i 用户进行排序来进行用户推荐。类似于商品推荐，使用准确度和召回率以及 MAP 来评价用户推荐的性能。

(2)实验结果： TMCAS 方法和对比方法的比较如图 4 所示。由于 TMCAS 模型统一对类别、方面、方面情感和时间交互建模，因此其性能均优于对比方法，且建模这种交互能够识别一个用户是否喜欢某类别的商品(即 $p(c | u)$)或者在给定类别的情况下，是否喜欢该类别的某个方面(即 $p(a | u, c)$)。使用模型做出推荐时，也能检验所推荐的商品是否满足用户的偏好。但从图 4 可以看出，TMCAS 模型在 Tripadvisor 数据集上的性能改进较小。与 4.2.1 节的分析结果类似，这是因为 Tripadvisor 数据集中的评论数相对较少，因此模型不易判断商品的哪个方面好哪个方面坏。与 Tripadvisor 数据集相比，Amazon 数据集的评论数是其评论数的 2 倍，因此

TMCAS 模型能够利用方面和情感来显著改进推荐的性能。

5 结束语

本文提出一个面向时序感知的多类别商品方面情感分析推荐模型 TMCAS，该模型通过对商品类别、商品方面、方面情感和时间之间的依赖关系统一建模，能够为用户提供时序感知的商品推荐或为商品提供时序感知的用户推荐。由于 TMCAS 模型同时考虑了用户方面情感随时间变化的特点以及用户方面偏好具有类别感知的特点，因此该模型能够根据用户在不同时间对不同类别商品的方面偏好进行推荐，并给出推荐的理由。在两个真实数据集上的实验结果表明，与其它基于静态方面情感分析的推荐模型和考虑了时间因素的推荐模型相比，本文提出的模型在 top-N 商品推荐和用户推荐准确率、召回率及 MAP 指标上均获得了显著改善。然而，本文提出的模型没有考虑用户的方面数字评分，而利用方面数字评分和评论文本对发现用户偏好能够起到相互补充的作用。因此，下一步将对这一问题进行深入研究，以期进一步提高推荐的准确率。

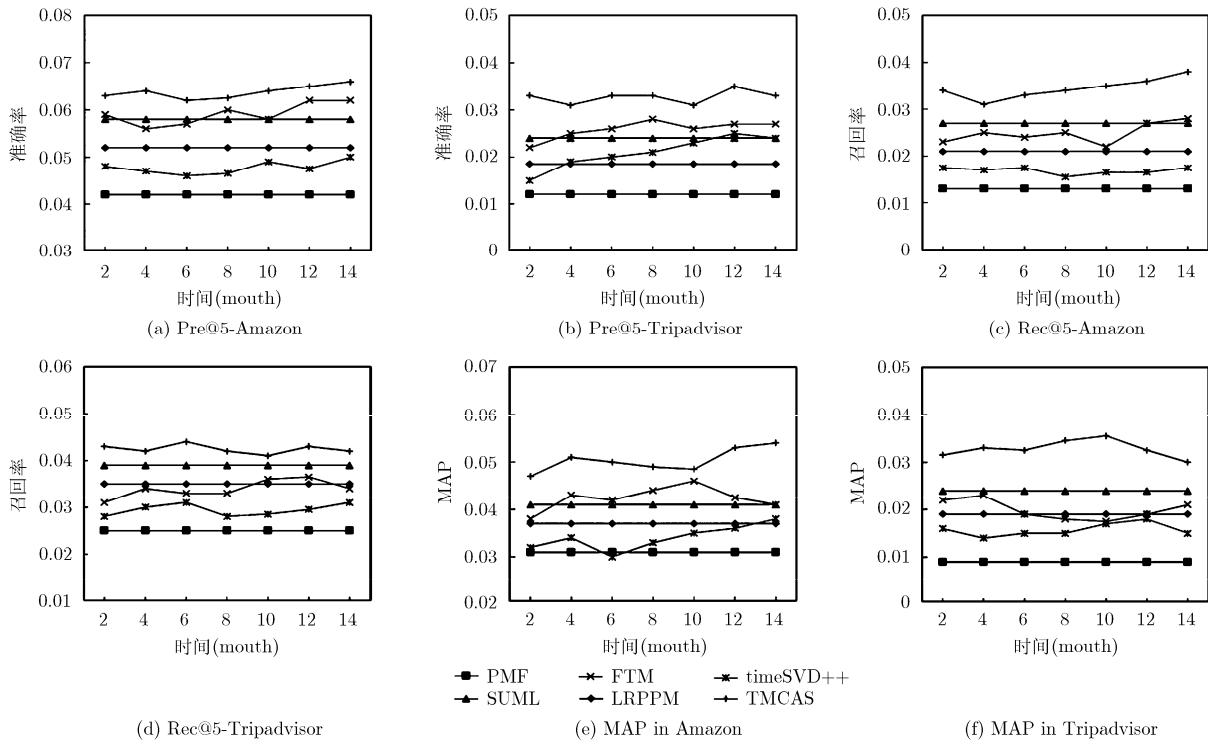


图 4 面向时间的用户推荐

参考文献

[1] LEUNG W K, CHAN C F and CHUNG F L. Integrating

collaborative filtering and sentiment analysis: A rating inference approach[C]. Proceedings of European Conference on Artificial Intelligence Workshop, Riva del Garda, 2006:

- 300–307.
- [2] PERO Š and HORVAT T. Opinion-driven matrix factorization for rating prediction[C]. Proceedings of User Mode-ling, Adaptation, and Personalization, Rome, Italy, 2013: 1–13. doi: 10.1007/978-3-642-38844-6_1.
- [3] SCHOUTEN K and FRASINCAR F. Survey on aspect-level sentiment analysis[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2016, 28(3): 813–830. doi: 10.1109/TKDE.2015.2485209.
- [4] WANG Feng and CHEN Li. Review mining for estimating users' ratings and weights for product aspects[J]. *Web Intelligence*, 2015, 13(3): 137–152. doi: 10.3233/WEB-150317.
- [5] OU W and HUYNH V N. Rating supervised latent topic model for aspect discovery and sentiment classification in on-line review mining[C]. Proceedings of 13th International Conference on Modeling Decisions for Artificial Intelligence, Sant Julià de Lòria, Andorra, 2016: 151–164. doi: 10.1007/978-3-319-45656-0_13.
- [6] MUSTO C, DE GEMMIS M, SEMERARO G, *et al.* A multi-criteria recommender system exploiting aspect-based sentiment analysis of users, reviews[C]. Proceedings of the Eleventh ACM Conference on Recommender Systems, Como, Italy, 2017: 321–325. doi: 10.1145/3109859.3109905.
- [7] ZHANG Yongfeng, ZHANG Haochen, and ZHANG Min, *et al.* Do users rate or review? boost phrase-level sentiment labeling with review-level sentiment classification[C]. Proceedings of the 37th International ACM SIGIR Conference on Research and Development in Information Retrieval, Gold Coast, Australia, 2014: 1027–1030.
- [8] WANG Shuai, CHEN Zhiyuan, and LIU Bing. Mining aspect-specific opinion using a holistic lifelong topic model[C]. Proceedings of the 25th International Conference on World Wide Web, Montreal, Canada, 2016: 167–176. doi: 10.1145/2872427.2883086.
- [9] ZHANG Yongfeng, LAI Guokun, ZHANG Min, *et al.* Explicit factor models for explainable recommendation based on phrase-level sentiment analysis[C]. Proceeding of The 37th International ACM SIGIR Conference on Research & Development in Information Retrieval. Gold Coast, Australia, 2014: 83–92. doi: 10.1145/2600428.2609579.
- [10] CHEN Xu, XU Tao, ZHANG Yongfeng, *et al.* Learning to rank features for recommendation over multiple categories[C]. Proceedings of the 39th International ACM SIGIR conference on Research and Development in Information Retrieval, Pisa, Italy, 2016: 305–314. doi: 10.1145/2911451.2911549.
- [11] WU Yao and ESTER M. FLAME: A probabilistic model combining aspect based opinion mining and collaborative filtering[C]. Proceedings of the Eighth ACM International Conference on Web Search and Data Mining, Shanghai, China, 2015: 199–208. doi: 10.1145/2684822.2685291.
- [12] BAUMAN K, LIU Bing, and TUZHILIN A. Aspect based recommendations: recommending items with the most valuable aspects based on user reviews[C]. Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Halifax, Canada, 2017: 717–725. doi: 10.1145/3097983.3098170.
- [13] HE Yulan, LIN Chenghua, GAO Wei, *et al.* Dynamic joint sentiment-topic model[J]. *ACM Transactions on Intelligent Systems & Technology*, 2014, 5(1): 1–21.
- [14] DERMOUCHE M, VELCIN J, KHOUAS L, *et al.* A Joint model for topic-sentiment evolution over time[C]. Proceedings of 2014 IEEE International Conference on Data Mining, Shenzhen, China, 2014: 773–778. doi: 10.1109/ICDM.2014.82.
- [15] HU Yan, XU Xiaofei, and LI Li. Analyzing topic-sentiment and topic evolution over time from social media[C]. Proceedings of the 9th International Conference on Knowledge Science, Engineering and Management, Passau, Germany, 2016: 97–109. doi: 10.1007/978-3-319-47650-6_8.
- [16] KOREN Y. Collaborative filtering with temporal dynamics [C]. Proceedings of the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Paris, France, 2009: 447–456. doi: 10.1145/1557019.1557072.
- [17] XIONG Liang, CHEN Xi, and HUANG Tzukuio, *et al.* Temporal collaborative filtering with bayesian probabilistic tensor factorization[C]. Proceedings of the SIAM International Conference on Data Mining, Columbus, USA, 2010: 211–222.
- [18] RAFAILIDIS D and NANOPOULOS A. Modeling users preference dynamics and side information in recommender systems[J]. *IEEE Transactions on Systems, Man, & Cybernetics: Systems*, 2016, 46(6): 782–792.
- [19] LIU Xin. Modeling users, dynamic preference for personalized recommendation[C]. Proceedings of the Twenty-Fourth International Joint Conference on Artificial Intelligence, Buenos Aires, Argentina, 2015: 1785–1791. doi: 10.1137/1.9781611972801.19.
- [20] SHANG Yanmin, XU Kefu, ZHANG Chuang, *et al.* FTM: Recommending the right items for user temporal interests with matrix factorization through topic model[C]. Proceedings of the IEEE First International Conference on Data Science in Cyberspace, Changsha, China, 2017: 189–198. doi: 10.1109/DSC.2016.20.
- [21] MNIH A and SALAKHUTDINOV R. Probabilistic matrix factorization[C]. Proceedings of the Twenty-First Annual Conference on Neural Information Processing Systems, Vancouver, Canada, 2007: 1257–1264.
- 丁永刚: 女, 1966年生, 副教授, 硕士生导师, 博士, 研究方向为机器学习、智能推荐、信息检索。
- 李石君: 男, 1964年生, 教授, 博士生导师, 研究方向为机器学习、数据挖掘、信息检索。
- 付星: 男, 1988年生, 讲师, 博士, 研究方向为谐波分析、小波理论、测度理论、泛函分析。
- 刘梦君: 男, 1988年生, 讲师, 博士, 研究方向为数据挖掘、移动计算、分布式系统。