



百度推荐引擎实践系列（一）：策略篇

赵岷
百度 - 推荐与个性化部
2012. 10.20





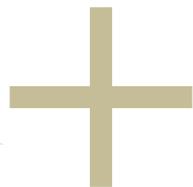
为何推荐？

百度推荐与个性化实践

推荐系统设计要素

推荐系统设计之策略篇

信息爆炸
信息过载



知识匮乏
时间有限

方法 1
用户主动搜索

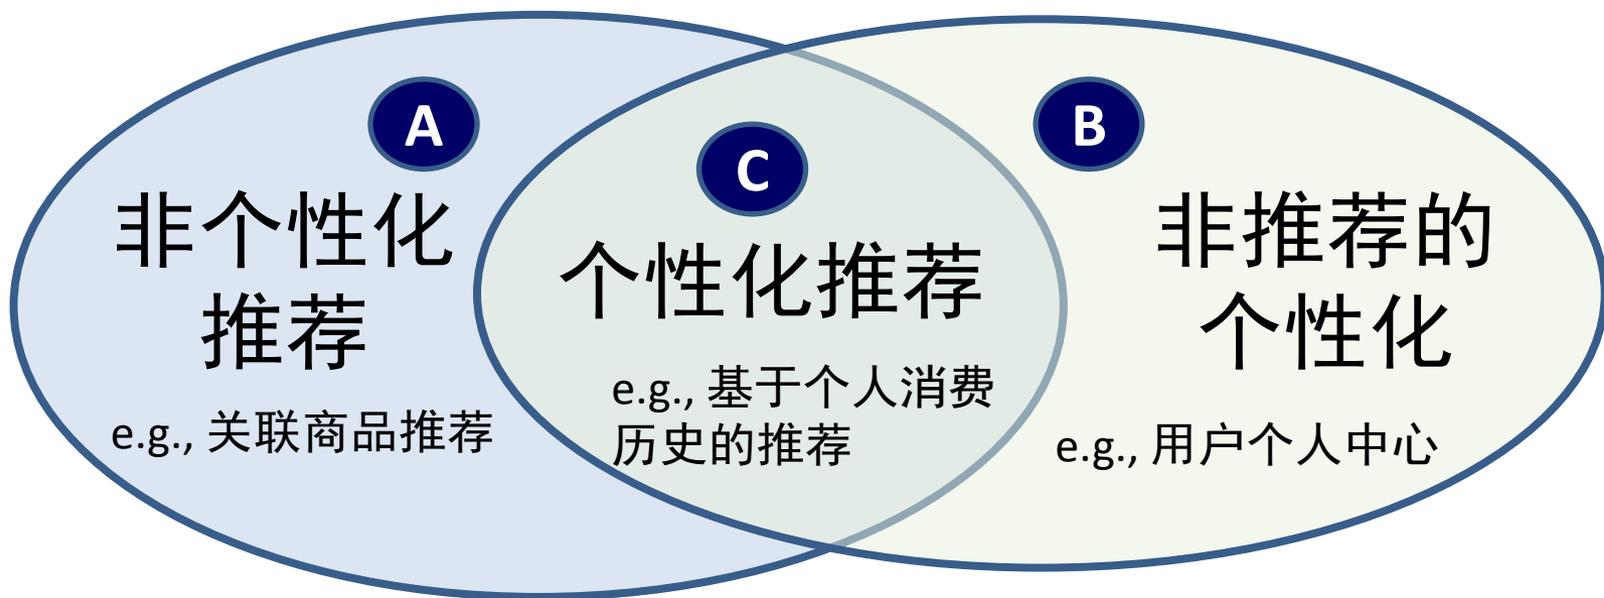
方法 2
系统主动推荐



用户知道自己想要什么
&& 知道如何描述自己的需求

用户有需求 &&
不知道怎样描述自己的需求
or 不知道去哪寻找 / 懒得找

- ✓ 目标：协助用户高效便捷地寻找/发现信息
 - ✓ 管理&组织、搜索&引导、浏览&发现



- ✓ 产品可兼顾三者，搜索与推荐功能有机结合

- ✓ 提升用户体验和满意度，增强用户粘性
 - 消费需求的变化：
 - 单一/从众 → 多样/个性/品位
 - 信息的极大丰富
 - 需要有效的信息过滤工具
- ✓ 用户数据的积累已经可以支撑个性化应用
 - 能够在线获得大量用户行为、偏好数据
 - SNS的流行，用户逐渐养成分享和接受推送的习惯

✓ 个性化营销

– → 电子商务公司

✓ 个性化广告

– → 以面向个人用户的广告为主要盈利模式的互联网公司

- ✓ — 除了广告/商品推荐之外，推荐还能带来什么显著收益？
- ✓ — 推荐是锦上添花，还是雪中送炭？独立推荐产品能成功吗？
- ✓ — 会出现像搜索引擎一样成功的推荐引擎吗？或者，推荐引擎将与搜索引擎合二为一？
- ✓ 以上，期待大家的实践 😊



为何推荐？



百度推荐与个性化实践

推荐系统设计要素

推荐系统设计之策略篇

例：个性化上网入口 -- 百度新首页





经验:2890/4000

我的知道

我的提问

我的回答

我的评论

我的赞同

▶ 为我推荐的提问

我的求助

我的成长

我的任务

我的物品

我的团队

财富商城

我的设置

标题 (共247条)

安徽有BEC高级考点吗? 有的话在哪报名以及报名... [英语考试]

10 BEC口语考试时间不合适, 可以申请改时间吗, 本... [英语考试]

1 考BEC高级考试心得? [英语考试]

1 急需BEC中级考试的最终复习资料啊..... [英语考试]

20 谁有英语BEC证件的清晰版扫描件发给我一份 要... [英语考试]

10 新东方BEC主讲谢姣岳的中级口语教材 谁能帮忙... [英语考试]

黄山英语BEC在哪里报名 [英语考试]

推荐一些考bec中级的好方法, 我打算下半年考, ... [英语考试]

bec中级写报告与商务建议的格式是什么 [英语考试]

求助BEC中级的复习资料 [英语考试]

求教BEC高级 四级630 六级590 托福9... [英语考试]

BEC考试还有15天, 做了半个月的题, 错的比较... [英语考试]

有无2012中级BEC全套练习资料。 [英语考试]

我想大三上个学期考BEC (就是下个学期), 老师... [英语考试]

考BEC的资料谁有啊? [英语考试]

回答数 提问时间

0 2012-5-20

1 2012-5-20

2 2012-5-20

1 2012-5-20

0 2012-5-13

0 2012-5-17

1 2012-5-17

2 2012-5-16

1 2012-5-15

0 2012-5-19

0 2012-5-21

1 2012-5-18

0 2012-5-14

2 2012-5-17


2 2012-5-12

共有51篇帖子 1 2 下一页 尾页

【如此倾心】[11.10-19]林心如会红长时间的!

只看楼主

1楼



xinanshi da
3位粉丝

核心会员



不是我盖的，我关注过的女星算比较多的吧，林老板个性人品都算是上乘了，从偶像，一步一步踏实地走向实力，刚开始并非倾城的她，现在确实散发了一种美丽，从纯情的瑶女郎，到如今各种差异的角色的成功塑造，虽然在电影上的作品较少，在电视剧这个版块上，确实绝对的实力派了，对后面的更年轻的演员也很是照顾，这个他们自己都这么感谢心如姐的，只要，她愿意，她会成功塑造更多不同以往的角色人物，她可以红得更久，这种红，不是那种简单的明星的红了，应该说是表演艺术的境界吧。

推荐 相关图片搜索



林心如高中时的照片



林心如的家人



还珠格格林心如



林心如弟弟

fm.baidu.com 百度随心听

当前频道：私人频道 换台

499 31 26



The First Cut Is The ...

《The Very Best Of Sheryl Crow》

sheryl crow

I would have given you all of my heart
But there's someone who's torn it apart
And he's taken just all that I had
But if you want I'll try to love again
Baby, I'll try to love again but I know

The first cut is the deepest

00:14

分享到

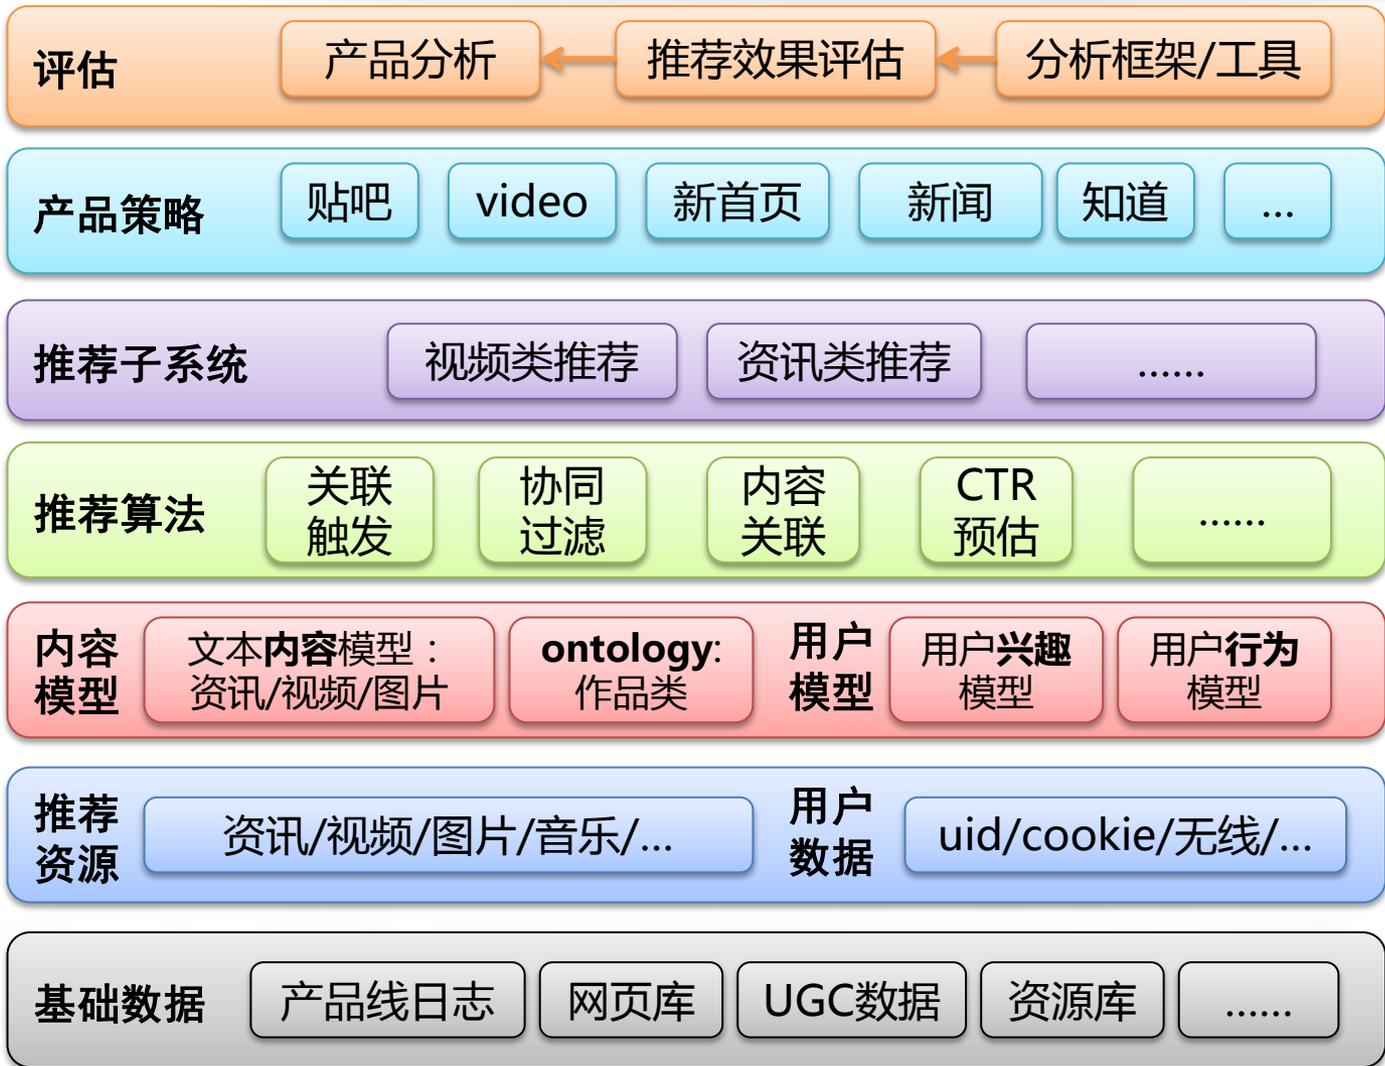


✓ 全类型

- 资讯  [贴吧](#)  [新闻](#)  [知道](#)  [百科](#)  [文库](#)
- 多媒体  [图片](#)  [视频](#)  [百度音乐](#)
- LBS、APP  [地图](#)  [百度身边](#)  [百度应用](#)  [百度游戏](#)

✓ 全方位

- 个人上网入口、各垂直领域、PC+无线



架构
在线服务
流式计算
算法平台
数据仓库

为何推荐？

百度推荐与个性化实践



推荐系统设计要素

推荐系统设计之策略篇

- ✓ Task 1: 通过人的行为/偏好/兴趣、事物的特性等建立事物间和人之间的关联
 - 行为：浏览购买、地理位置、Social Network、.....
 - 口味：吃喝玩乐、衣食住行、.....
- ✓ Task 2: 把关联的人或物推荐给人
 - 书籍、电影、音乐、文章、网站.....
 - 商品、广告.....
 - 人、团体、活动.....



- 1 ✓ 需求分析和用户调研
- 2 ✓ 功能设计
- 3 ✓ 界面设计
- 4 ✓ 架构设计
- 5 ✓ 算法设计
- 6 ✓ 系统评测

~~ 不同推荐系统各部分重要程度不同 ~~

- ✓ 为谁（例）：
 - 新用户：兴趣未知，着重多样性、新热
 - 老用户：兴趣已知，着重个性化
- ✓ 推荐什么（例）：
 - 价格一致，用户经常购买的类别
 - 书、电影、音乐、文章 → 以用户对内容主题的兴趣为主
 - 价格不一致，用户经常购买的类别
 - 服饰、日用百货 → 视觉、品牌、价格、内容
- ✓ 何时（例）：
 - Email VS. 手机短信 VS. APP推送
 - 短期、长期、周期（节假日、季节、.....）
- ✓ 何地（例）：
 - 商家、优惠券推送

✓ 产品分类 (例)

- 文本：新闻、博客、小说、论文、.....
- 图片：风景、商品、旅游、.....
- 音频：歌曲、歌手、专辑、.....
- 视频：电影、电视剧、综艺节目、短视频、.....
- 其他：app、位置服务、.....
- SNS：人、群组、.....
- 混合类别~~

✓ 数据 (例)：文本或其他内容 + metadata + 用户行为 + SNS

✓ 功能 (例)

- 1) item → item list：e.g., 关联商品、关联视频、关联app、关联网站
- 2) item set → item set list：e.g., 关联列表、关联专辑
- 3) user → item list、item set list：e.g., 您可能喜欢的XXX
- 4) user → user list、user set list：e.g., 您可能感兴趣的XXX (人、群组)

考虑因素：

-- 用户是否需要？

-- 系统收益？

-- 数据是否支持？

--

- ✓ 如何将推荐结果呈现给用户？
- ✓ 如何收集用户信息和反馈数据？
- ✓ 目的：
 - 提高用户满意度，达到推荐目的
 - 更多更好地收集高质量的用户反馈
 - 准确评测推荐算法效果

- ✓ 大规模存储
- ✓ 分布式计算
- ✓ 用户量、访问频次、峰值
- ✓ 实时响应的要求：
 - 毫秒级、秒级、小时级？
- ✓ 硬件资源的最大利用

- ✓ 优化准则：
 - 准确性、多样性、新颖性、覆盖率、时效性、……
- ✓ 数据预处理
- ✓ 离线算法
- ✓ 在线算法
- ✓ 功能实现策略
- ✓ 推荐解释
 - 对消费代价大的（时间、金钱）item尤其重要

- ✓ 上线前：基于人工标注评测集
- ✓ 上线后：
 - 基于用户点击数据
 - 将用户显示/隐式反馈转化为评测集
 - 基于A/B测试
 - 点击率、后续步长、转化率、.....
 - 整体收益 VS. 各模块内部收益
 - 产品指标
 - 用户指标：高收益用户、低收益用户
 - 每个产品特性导致不同的评估指标
 - 如何评估用户需求满足度？

为何推荐？

百度推荐与个性化实践

推荐系统设计要素

推荐系统设计之策略篇



推荐系统设计之策略篇

功能分析、数据分析、算法设计

- ✓ 用户数：万 → 十万 → 百万 → 千万 → 亿
- ✓ 用户群体：低端/高端、大众/小众、职业、年龄.....
- ✓ 推荐功能：
 - 推荐内容：资讯、视频、图片、.....
 - 个性化？非个性化？
 - Session？Cookie？用户？
 - Top-N？列表浏览？
 - 实时反馈的更新：点击、收藏、喜欢、删除、换一批
 - 用户模型的更新：实时、小时级、天级、周级？

✓ 例1：知道问题推荐

- 用户：知道产品相对资深用户，各领域都有
- 推荐功能：
 - 推荐内容：知道待回答问题
 - 是否个性化：针对特定用户的个性化推荐，和用户历史行为偏好相关
 - 展现形态：个人中心列表浏览 & 特定场景推送
 - 实时反馈：点击查看、回答
 - 时效性需求：固定周期更新 or 根据用户行为实时调整

✓ 例2：贴吧帖子推图片、视频

- 用户：浏览该帖子的用户，可能是贴吧忠实用户或搜索带来的非贴吧用户
- 推荐功能：
 - 推荐内容：帖子相关的图片或视频
 - 是否个性化：非个性化的关联推荐，每个用户看到的都一样
 - 展现形态：关联列表（文字标题+多媒体内容）
 - 实时反馈：点击查看
 - 时效性需求：固定周期更新（旧帖）or 实时关联计算（新帖）

推荐系统设计之策略篇

功能分析、数据分析、算法设计

- ✓ Item
 - 内容：文本、图片、音频、视频
 - Ontology、tag
- ✓ 用户
 - profile
- ✓ 用户-item行为数据
 - 点击、收藏、删除、观看、评分历史
- ✓ 关键：各类数据是否充足？可用性如何？

界面1：



界面2：



界面3：



- ✓ Explicit feedback
 - 评分、收藏、推荐/分享、购买、评论
- ✓ Implicit feedback
 - 点击浏览、下载、停留观看时间
- ✓ 理想：大量准确的Explicit 反馈
- ✓ 折中：用Implicit 反馈补充
- ✓ 问题：Explicit与Implicit数据的整合



- ✓ 推荐算法设计与评估的基础
 - 数据充足，简单算法性能可以很好
 - 数据缺失，任何算法也不可能有很好的性能
- ✓ 要求：不仅要吸引用户提供反馈，而且要吸引用户提供准确反馈
 - 给用户充足便利的反馈机会
 - 促使用户提供准确反馈/反馈鉴别机制
 - 购买行为：主动搜索购买 VS. 促销购买
 - 浏览行为：排行榜的强引导作用

推荐系统之策略设计

功能分析、数据分析、算法设计

- ✓ 数据
 - 内容：文本、图片、音频、视频、.....
 - Metadata：Ontology/类别信息、tag、.....
 - 用户行为日志：点击、评分、.....
 - SNS：好友关系、群组关系、.....
- ✓ 同一个算法可实现不同功能；同一个功能可用不同算法实现
- ✓ 用户建模、内容建模：将用户、内容用特征向量描述
 - 属性、term、topic、.....
- ✓ 离线关联算法：计算<用户-用户>/<用户-item>/<item-item>关联并排序
 - **关联/相似度计算**
 - 基于内容的：专家标注、ontology、tag、文本/音频/图像/视频、.....
 - 基于用户行为的：统计方法、关联规则、相似度经验公式
 - 混合算法
 - **机器学习**
 - 协同过滤：knn、基于模型的、.....
 - 各种经典算法：分类、回归、聚类、图算法、.....

例：关联计算 – 基于内容的（专家标注）

Squeeze your search

Zero in on what you want with real-time suggestions.

Mood ▾

Feel Good **x**

- Humorous
- Touching
- Sentimental
- Witty
- Exciting
- Offbeat
- Stylized
- Captivating
- Clever

Plot ▾

Genres ▾

Time/Period ▾

Audience ▾

Praise ▾

Based on ▾

All | Movies | TV | Shorts | Free Online

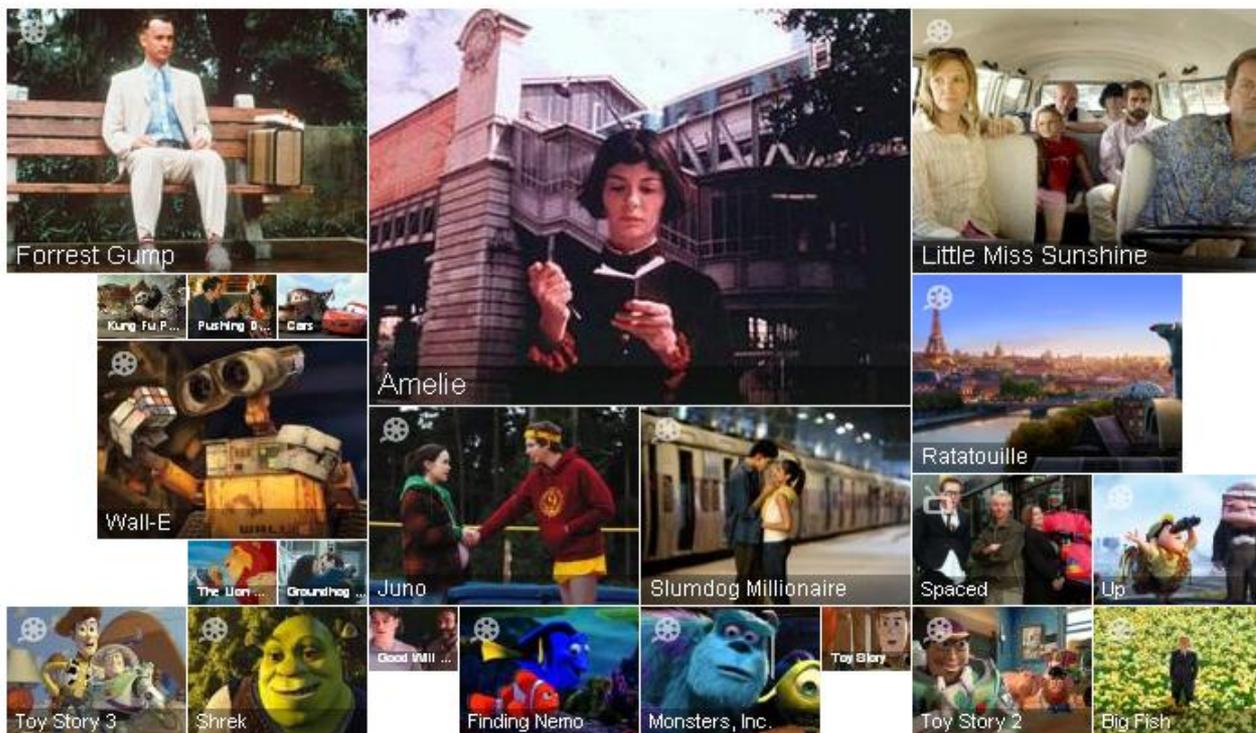
feel good

Go

3320 Results for: Feel Good (Mood)

Showing 1 - 22 of 3320

1 | 2 | 3 | 4 | 5 | Next >>



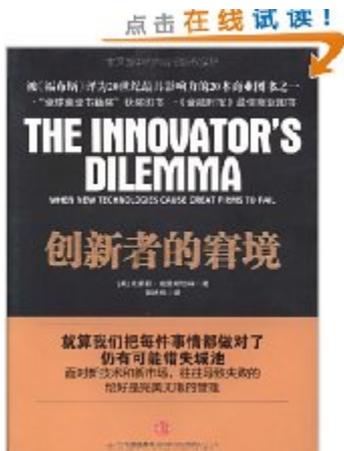
jinni.com:
Movie Genome

- ✓ 和其他领域紧密结合
 - 新闻、博客、... – 自然语言处理
 - 音乐 – 音频处理；图像 – 图像处理；视频 – 视频处理精度取决于相关领域的研究进展

- ✓ 专家标注：限于item数量少且有相对客观标准的领域
 - 电影 VS. 书籍
 - 自动专家发现？

- ✓ 可与Metadata结合：
 - ontology(量少准确)：商品分类
 - 分类排行榜：很土很有效的推荐列表
 - tag(量大不准确)

例：关联计算 – 基于用户行为的（统计）



创新者的窘境 [平装]

~ 克莱顿·克里斯坦森 (Clayton M. Christensen) (作者), 胡建桥 (译者)

★★★★☆ (10 个用户评论)

市场价: ¥ 38.00

卓越价: **¥ 22.40** 此商品可以享受**免费送货** [详情](#)
为您节省: **¥ 15.60 (5.9折)**

现在有货。
由卓越亚马逊直接销售和发货。

关键在于用户是否需要此功能
不在于算法简单或复杂

浏览此商品的顾客最终购买



81% 的顾客看完这一页后购买了此商品
创新者的窘境 - 克莱顿·克里斯坦森 (Clayton M. Christensen) 平装 ★★★★★ (10)
¥ 22.40



7% 的顾客看完这一页后购买了
创新的艺术 - 汤姆·凯利 (Tom Kelley) 平装 ★★★★★ (11)



5% 的顾客看完这一页后购买了
重来: 更为简单有效的商业思维 - 贾森·弗里德 (Jason Fried) 平装 ★★★★★ (47)
¥ 22.80



4% 的顾客看完这一页后购买了
设计心理学 - 唐纳德·A·诺曼 (Donald Arthur Norman) 平装 ★★★★★ (46)
¥ 19.50

- ✓ 基本假设
 - 过去经常被一起频繁消费的商品，今后也会被一起消费
- ✓ 算法：
 - 根据事先确定的支持度、置信度、提升度等，计算关联商品
- ✓ 成熟的商业应用
 - 电信套餐定制、超市捆绑销售
- ✓ 特点：
 - 适合Session/Transaction数据
 - 难以对长尾商品作有效预测
 - 用户的消费差异性被忽略，不是很适合个性化推荐

- 将用户用item向量表示，或将item用用户向量表示
 - 向量上的取值可以是用户对item的评分或其他行为取值
- 常用的相似度计算公式（也可用于内容关联计算）

- cosine

$$\text{sim}(i, j) = \cos(\vec{i}, \vec{j}) = \frac{\vec{i} \cdot \vec{j}}{\|\vec{i}\| * \|\vec{j}\|} = \frac{\sum_{u \in U} R_{u,i} R_{u,j}}{\sqrt{\sum_{u \in U} R_{u,i}^2} \sqrt{\sum_{u \in U} R_{u,j}^2}}$$

- adjusted cosine

$$\text{sim}(i, j) = \frac{\sum_{u \in U} (R_{u,i} - \bar{R}_u)(R_{u,j} - \bar{R}_u)}{\sqrt{\sum_{u \in U} (R_{u,i} - \bar{R}_u)^2} \sqrt{\sum_{u \in U} (R_{u,j} - \bar{R}_u)^2}}$$

- pearson correlation

$$\text{sim}(i, j) = \frac{\text{Cov}(i, j)}{\sigma_i \sigma_j} = \frac{\sum_{u \in U} (R_{u,i} - \bar{R}_i)(R_{u,j} - \bar{R}_j)}{\sqrt{\sum_{u \in U} (R_{u,i} - \bar{R}_i)^2} \sqrt{\sum_{u \in U} (R_{u,j} - \bar{R}_j)^2}}$$

- ✓ 关联融合
 - 数据融合 → 关联算法
 - 不同关联算法 → 结果融合
- ✓ 关联结果应用
 - 直接用于相关推荐
 - 个性化推荐：用户对特定item的偏好 → 关联扩展



✓ 优点：不依赖domain

协同过滤		
基本假设	过去行为偏好相似的用户，今后行为偏好也相似	
基本思路	<p>基于近邻的</p> <p>为每个用户/商品计算相似用户/商品，再利用相似用户/商品的历史进行预测： 基于部分user-item关系 相似度计算 → k近邻 → 偏好预测</p>	<p>基于模型的</p> <p>用隐变量刻画用户和商品间的关系： 部分user-item关系 → 用隐变量刻画user-item关系 → 偏好预测</p>
	商业应用	<p>在线购物网站，如Amazon的商品关联推荐</p> <p>学术研究热点，实际应用不太普及</p>
特点	适于个性化推荐	

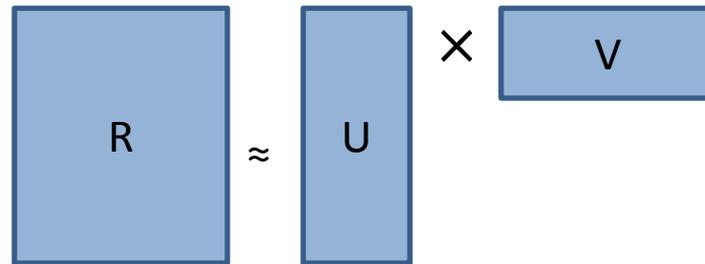
✓ MF (矩阵分解)

$$R \approx U^T V$$

$$\hat{r}_{ui} = \sum_{k=1}^K u_{ku} v_{ki} = \mathbf{u}_u^T \mathbf{v}_i$$

$$\min_{\mathbf{U} \in \mathbb{R}^{k \times m}, \mathbf{V} \in \mathbb{R}^{k \times n}} \sum_{(u,i) \in \mathcal{R}} (r_{ui} - \mathbf{u}_u^T \mathbf{v}_i)^2 + \lambda (\|\mathbf{U}\|_F^2 + \|\mathbf{V}\|_F^2)$$

SVD, set $A=U \Sigma$, $B=V^T$

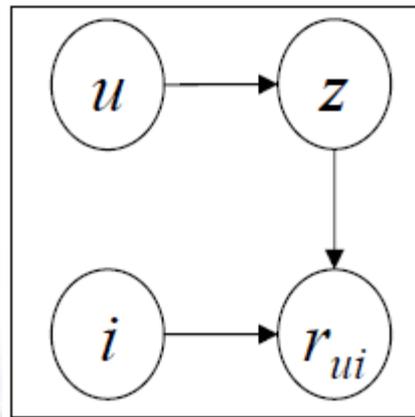


✓ PLSA (概率隐语义分析)

$$P(r_{ui}|u, i) = \sum_{z=1}^k P(z|u) P(r_{ui}; \mu_{zi}, \sigma_{zi})$$

$$P(r_{ui}; \mu_{zi}, \sigma_{zi}) = \frac{1}{\sqrt{2\pi}\sigma_{zi}} \exp \left[-\frac{(r_{ui} - \mu_{zi})^2}{\sigma_{zi}^2} \right]$$

$$\hat{r}_{ui} = \sum_{z=1}^k P(z|u) \int r P(r; \mu_{zi}, \sigma_{zi}) dr = \sum_z P(z|u) \mu_{zi}$$



✓ 将用户-item行为数据： $\langle \text{user}, \text{item}, \text{点击} \rangle$ ，转换为

	用户属性1	用户属性2	...	item属性1	item属性2	...	$\langle u, i \rangle$ 属性1	$\langle u, i \rangle$ 属性2	...	是否点击
$\langle u1, i1 \rangle$	a	ll	...	A	t	...	22	0.4	...	1
$\langle u1, i2 \rangle$	b	lll	...	B	p	...	587	0.8	...	0
...
$\langle un, im \rangle$	a	l	...	B	m	...	31	0.01	...	1

- 可使用各种机器学习分类算法（把难点转换成属性构造和选择问题）
- 参考：个性化广告的CTR（点击率）预估模型
 - 但是，很多推荐不是只以提升CTR为目标
 - CTR提升，用户满意度不一定提升（吸引眼球的推荐不一定是好的推荐）

- ✓ 一般算法的优化目标：相对单一和明确
 - 分类：分类错误率
 - 信息检索：准确率、召回率、.....
- ✓ 推荐系统
 - 不同功能的优化目标不同；不同发展阶段的优化目标不同
 - 不同优化目标可能需要不同的数据和算法
 - 同一算法在不同数据集上效果差异很大，数据在不断变化
 - Item/user比，新老用户比，稀疏度，时效性
 - 推荐系统本身影响收集的用户行为数据
 - 推荐列表 → 用户点击 → 根据点击数据优化推荐列表

80% \rightarrow 90% \checkmark

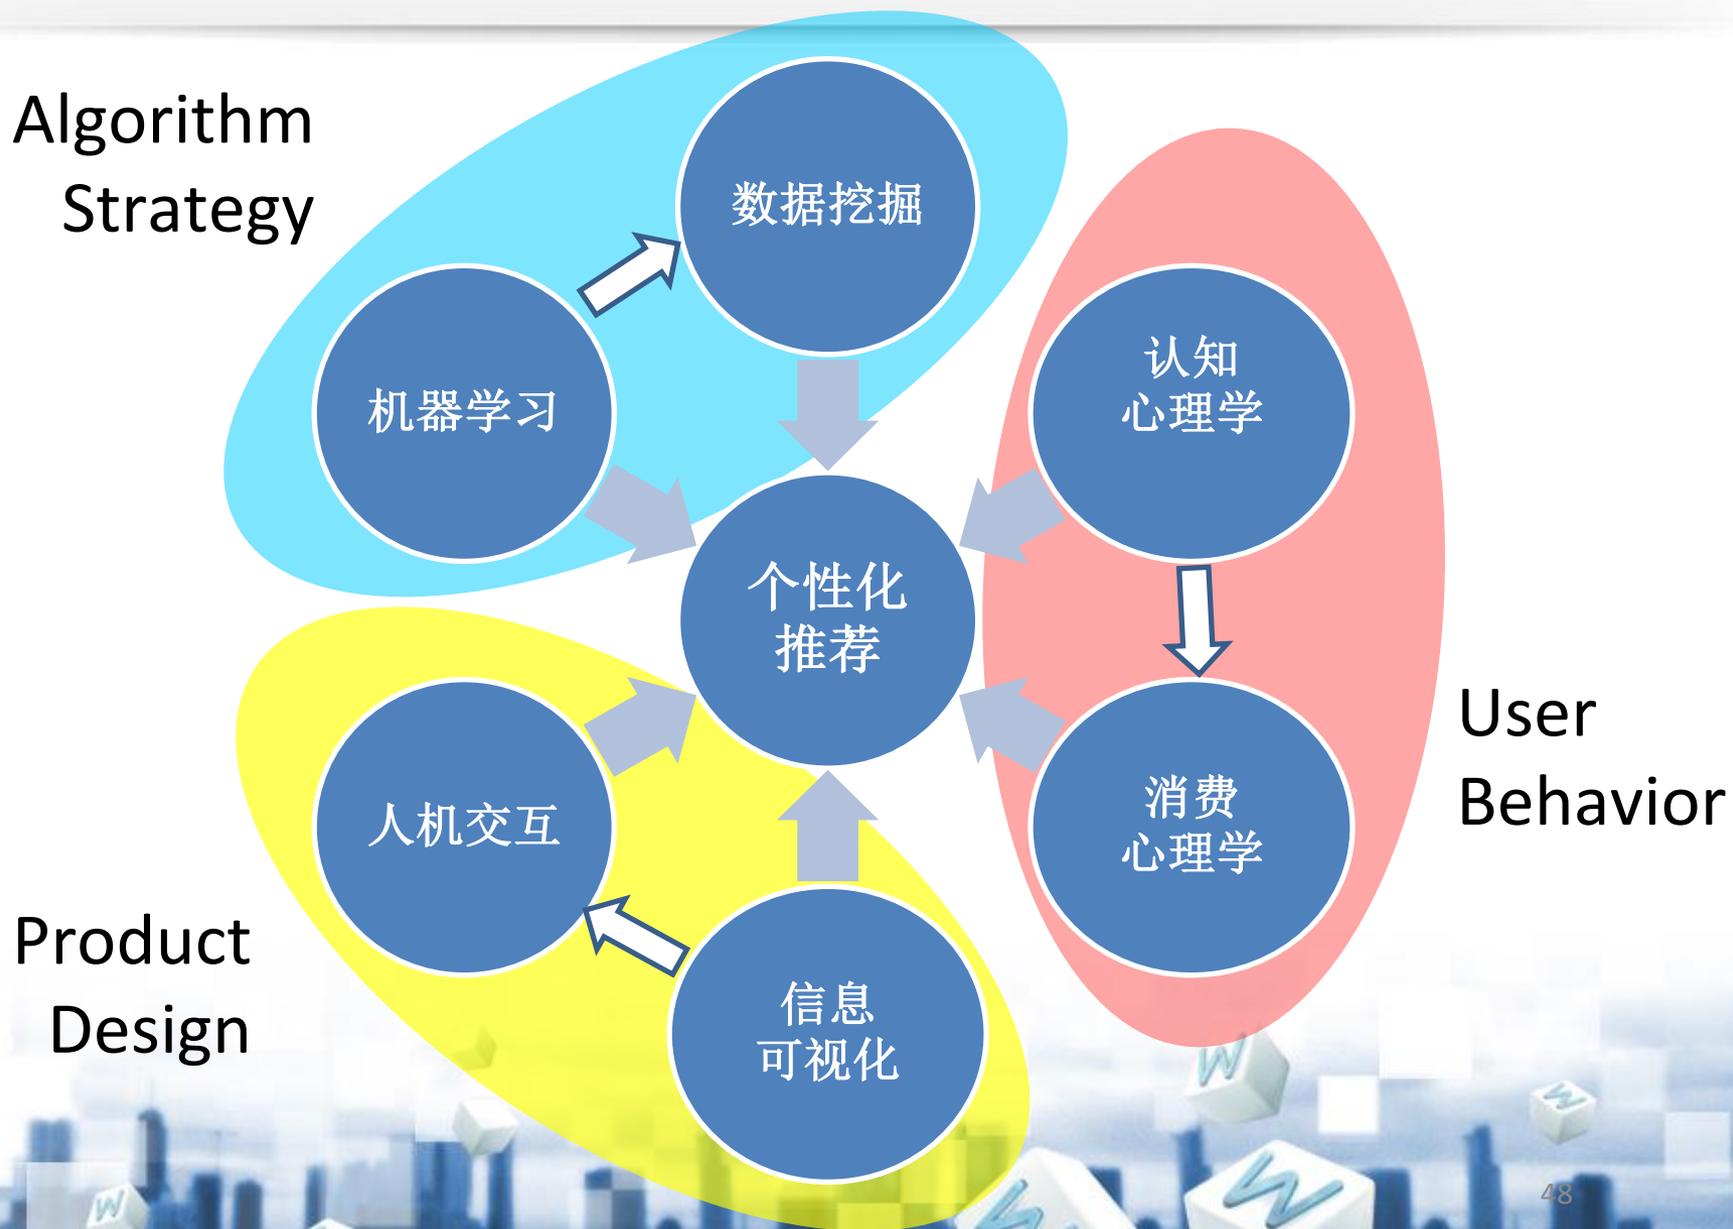
10% \rightarrow 20% $\times \rightarrow$ 换一种方法吧~~

不能因为手里有把锤子，就把所有问题都当作钉子~~



推荐系统之策略设计

一些感受



- ✓ “某某说：XX 算法效果很好/不好” 通常意味着 “某某有/没有适合该算法的数据”
 - 例：“基于SNS的算法效果很好”、“内容关联不靠谱”
- ✓ “在现有数据上优化” VS. “寻找更多的数据”
 - 不同阶段的重点
- ✓ 数据清理&整合



- ✓ 推荐策略和产品业务紧密耦合 → 领域知识的大量使用
 - 关联定义
 - 数据处理
 - 特征构建
 - 推荐解释
- ✓ “通用推荐引擎” VS. “垂直推荐引擎”
 - “通用系统平台+归一化数据+算法” + “垂直策略设计”

谢谢！

