动态贝叶斯网络点击模型

The Dynamic Bayesian Network Click Model

Liam Huang*

2018 年 4 月 3 日

*liamhuang0205@gmail.com

基础知识

目标问题

- Machine Learning Ranking 都是有监督学习.
- 对 query-document 相关性的人工标注成本高.
- 用户点击日志暗含了 query-document 相关性.
- 怎样利用用户点击日志，获得 query-document 相关性?

相关概念

- Click Through Rate：某种限制条件下的点击次数比上展现次数.
  - 全局下的：Global CTR $= \frac{\#\text{ clicks}}{\#\text{ shown docs}}$
  - 某 rank 位置上的：$\text{CTR}_r = \frac{\#\text{ clicks at rank r}}{\#\text{ shown docs at rank r}}$
- Examination：用户对展现结果的观察行为.
- Perceived Relevance：用户观察之后，根据展现情况感知的相关性.
- Click：用户的点击行为.
- Actural Relevance：用户点击后，根据页面实际内容判断的相关性.
- Position Bias：由于展现位置带来的对 CTR 的影响.

机器学习模型三要素

- 模型结构 ← 模型是如何描述目标问题的?
- 目标函数 ← 怎样评判模型效果的优劣?
- 优化算法 ← 怎样求解目标函数上的优化问题?

全都是套路.

Impressive Approaches[1]

Position Models

模型假设:

- Click = Examination + Perceived Relevance.
- $P(E = e \mid u, p) = P(E = e \mid p)$.
- $P(C = 1 \mid u, p, E = 1) = P(C = 1 \mid u, E = 1)$.

$$P(C = 1 \mid u, p) = \sum_{e \in \{0,1\}} P(C = 1 \mid u, p, E = e) \cdot P(E = e \mid u, p)$$
$$= \underbrace{P(C = 1 \mid u, E = 1)}_{\stackrel{\text{def}}{=} \alpha_u} \cdot \underbrace{P(E = 1 \mid p)}_{\stackrel{\text{def}}{=} \beta_p}$$

- 假设: $\beta_1 \stackrel{\text{def}}{=} 1$,
- 则 α_u 表示当 u 位于 rank 1 时的 CTR.

[1] Despite the impressive progress made so far, this goal has remained elusive. In this paper, we achieve this. ——PRIMES is in P

COEC (Clicks Over Expected Clicks) 模型

继续假设，β_p 对于所有 query 和 session 是一致的，则有：

$$\alpha_u \stackrel{\text{def}}{=} \frac{\sum_{i=1}^{N} c_i}{\sum_{i=1}^{N} \beta_{p_i}}.$$

问题：α_u 不仅包含了位置本身的信息（position bias），还包含了特定位置结果的平均相关性.

Examination 模型

解决: 在 N 个 session 中, 观察同一 URL 在不同位置的 CTR; 最大似然:

$$\alpha_u = \arg\max_{\alpha} \sum_{i=1}^{N} c_i \log(\alpha\beta_{p_i}) + (1 - c_i)\log(1 - \alpha\beta_{p_i}).$$

问题: 保证 $0 \leqslant \alpha\beta \leqslant 1$, 但无法保证 $0 \leqslant \alpha \leqslant 1$.

解决: 将 E 视作隐变量, 运用 Expectation-Maximization 算法解决.

问题: 原假设 $P(E = e \mid u, p) = P(E = e \mid p)$ 忽略了 URL 之间的相互作用.

Cascade Model

假设:

- Click = Examination + Perceived Relevance.
- 第 i 条结果的相关性: $P(A_i = 1) = \alpha_{u_i}$.
- 从第一条开始检查: $P(E_1 = 1) = 1$.
- 逐条检查: $P(E_i = 1 \mid E_{i-1} = 0) = 0$.
- 有点击后终止检查: $P(E_i = 1 \mid C_{i-1} = 1) = 0$.
- 无点击则继续检查: $P(E_i = 1 \mid C_{i-1} = 0) = 1$.

则有:

$$P(C_i = 1) = \alpha_{u_i} \prod_{j=1}^{i-1} (1 - \alpha_{u_j}).$$

问题:

- 点击了就满意了吗?
  - 无法处理多次点击的情况.
  - 无法区分看起来相关和实际上相关.
- 无法处理无点击的情况.

动态贝叶斯网络

模型

假设:

- Click = Examination + Perceived Relevance.
- 第 i 条结果的感知相关性: $P(A_i = 1) = a_{u_i}$.
- 从第一条开始检查: $P(E_1 = 1) = 1$.
- 逐条检查: $P(E_i = 1 \mid E_{i-1} = 0) = 0$.
- 有点击后实际相关性: $P(S_i = 1 \mid C_i = 1) = s_{u_i}$.
- 无点击则不被满足: $P(S_i = 0 \mid C_i = 0) = 1$.
- 被满足则不再检查: $P(E_{i+1} = 0 \mid S_i = 1) = 1$.
- 不满足时可能继续检查: $P(E_{i+1} = 1 \mid S_i = 0, E_i = 1) = \gamma$.

实际相关性:

$$\begin{aligned} r_{u_i} &\stackrel{\text{def}}{=} P(S_i = 1 \mid E_i = 1) \\ &= P(S_i = 1 \mid C_i = 1) P(C_i = 1 \mid E_i = 1) \\ &= s_{u_i} a_{u_i}. \end{aligned}$$

概率图

- 框内：session 级别变量.
- 框外：query 级别变量.
- 黑底：非隐变量.
- 白底：隐变量.

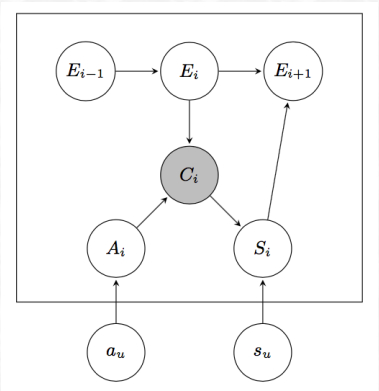

- 类似隐马模型.
- Expectaction-Maximization 算法求解.
- γ 体现用户耐性，可作为隐变量估计，也可作为超参数统一配置.

实验结果

超参数 $\gamma \stackrel{\text{def}}{=} 0.9$.

CTR 准确率

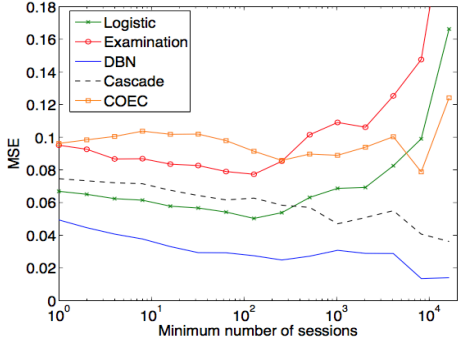

作为 ranking 信号

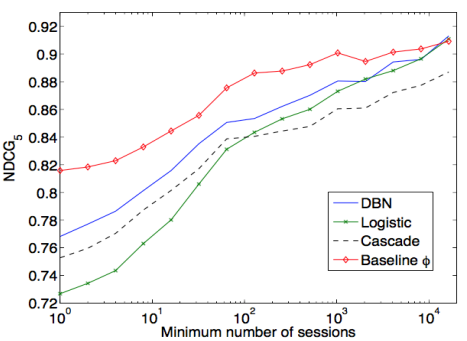

UGA