



Gleb Gusev et al.

Yandex NDA

February, 10, 2015

- 1 Относительные метрики в A/B тестировании.


- 1 Относительные метрики в A/B тестировании.
- 2 Агрегация зашумленных оценок

- 1 Относительные метрики в A/B тестировании.
- 2 Агрегация зашумленных оценок
- 3 Контрфактическое обучение в офлайне

- 1 Относительные метрики в A/B тестировании.
- 2 Агрегация зашумленных оценок
- 3 Контрфактическое обучение в офлайне
- 4 Прочее

- 1 Относительные метрики в A/B тестировании
- 2 Агрегация зашумленных оценок
- 3 Контрфактическое обучение в офлайне
- 4 Прочее

A/B testing background



- Вычисляется **разница между средними значениями**
 $\Delta = \mu_B - \mu_A$
- Применяется статистический тест (обычно Стьюдента), чтобы отбросить гипотезу о том, что разница матожиданий равна нулю.
- Способность метрики показывать статистически значимую разницу в тех случаях, когда эффект есть, называется **чувствительностью**.
- Улучшение чувствительности метрики — **важная и трудная задача**.

Интерпретируемость: метрика пропорциональна деньгам?


- Если X — это аддитивная награда, то среднее значение имеет смысл
- Если событие — это клик, а X — это dwell time (время просмотра), тогда награда не пропорциональна X .

Чувствительность: почему мы ограничиваем себя?

- Метрика Δ основана на **абсолютных** характеристиках μ_A, μ_B двух распределений.
- Мы предложим **относительную** метрику, которая "напрямую" сравнивает два распределения.

Предположения

- Есть скрытая бинарная величина $Y \in \{0, 1\}$, посредством которой значение X зависит от варианта Z :
 $P(X | Z, Y) = P(X | Y)$



- Y отвечает за успех: $Y = 1 \Leftrightarrow$ заработали доллар.

Модель данных

- Скрытые **вероятности успеха**
 $p_A := P(Y = 1 \mid Z = A), p_B := P(Y = 1 \mid Z = B).$
- Скрытые условные распределения $F_0(x), F_1(x)$ величин $X \mid Y = 0$ и $X \mid Y = 1$.
- Наблюдаемые распределения (их выборки)

$$\begin{cases} D_A(x) = p_A F_1(x) + (1 - p_A) F_0(x) \\ D_B(x) = p_B F_1(x) + (1 - p_B) F_0(x) \end{cases} \quad (1)$$


Пример: событие — клик, X — dwell time

- F_0 — распределение Ландау ("конвертации" нет).
- F_1 — Логнормальное распределение (есть "конвертация").

Задача


- Оценить $\alpha := p_B - p_A$
- Для этого найти $p_A, p_B, F_0(x), F_1(x)$, удовлетворяющие системе:

$$\begin{cases} D_A(x) = p_A F_1(x) + (1 - p_A) F_0(x) \\ D_B(x) = p_B F_1(x) + (1 - p_B) F_0(x) \\ \int_{\mathbb{R}} F_j dx = 1, \quad j = 0, 1 \\ F_j(x) \geq 0, \quad j = 0, 1 \end{cases} \quad (2)$$




Решение

- Существует двух-параметрическое семейство решений.




Решение

- Существует двух-параметрическое семейство решений.
- Выбираем из них "крайнее" которое минимизирует $|\alpha| = p_B - p_A$ ($D_B - D_A = \alpha F_1 - F_0$).



Решение


- Существует двух-параметрическое семейство решений.
- Выбираем из них "крайнее" которое минимизирует $|\alpha| = p_B - p_A$ ($D_B - D_A = \alpha F_1 - F_0$).
- Знак α определяется тем, какое из F_0, F_1 - "хорошее".



Решение

- Существует двух-параметрическое семейство решений.
- Выбираем из них "крайнее" которое минимизирует $|\alpha| = p_B - p_A$ ($D_B - D_A = \alpha F_1 - F_0$).
- Знак α определяется тем, какое из F_0, F_1 - "хорошее".
- F_0, F_1, p_A, p_B содержательно зависят от пары D_A, D_B .

Пример двух распределений



Выбираем одно из двух

- Два гамма-распределения: $D_A(x) = \lambda e^{-\lambda x}$ и $D_B(x) = 4\lambda^2 x e^{-2\lambda x}$
- $\mathbb{E}(X \mid Y = 0) = \mathbb{E}(X \mid Y = 1)$.
- Но обычно предпочитают D_B !

- 1 Относительные метрики в A/B тестировании
- 2 Агрегация зашумленных оценок
- 3 Контрфактическое обучение в офлайне
- 4 Прочее

Постановка задачи

Данные на входе

- N работников (толокеров) выполняют M заданий: отвечают на вопросы.
- Работники не профи и халтурят, поэтому одно и то же задание попадает нескольким работникам (с *перекрытием*).
- На выходе наблюдаем **шумный лейбл** $y_{wj} \in L = \{0, 1\}$ работника w для задания j .

Цель: классическая

- На основе шумных лейблов получить информацию об **истинных лейблах** y_j .
- Стандартная метрика качества — доля правильно угаданных лейблов I_j (**точность, accuracy**).

Алгоритм MV (majority vote)

$$\hat{l}_j = \operatorname{argmax}_x (\sum_w \mathbb{I}(y_{wj} = x)).$$

Свойства

- Выдает детерминированное значение без оценки его вероятности
- Учитывает голоса разных работников с одинаковым весом.

Классическая модель

- Истинные лейблы z_j порождаются независимо из априорного распределения P_z на L .
- Наблюдаемый лейбл y_{wj} порождается из условного распределения $P(y | z_j)$.
- Это распределение задается стохастической матрицей $M = (m_{yz})$, которая может зависеть от работника w и от задания j .

Примеры

- GLAD (Witehill et al.): $m_{yz} = \frac{1}{1 + \exp(-\alpha_w \beta_j)}$
- DS (Dawid&Skene): $M = M^w$ индивидуальная для каждого работника. Чтобы уменьшить $\#$ параметров, вводят априорное распределение на M .

Обучение

- Если M не зависит ни от чего и $\operatorname{argmax}_y m_{yz} = z$, то MV является оценкой максимального правдоподобия при равномерном P_Z .
- GLAD, DS традиционно обучаются EM-алгоритмом:
 - Е-шаг: Вычисляем апостериорное $P_{\text{post}}(z_j | \hat{\Gamma}, y_{wj})$, где $\Gamma = ((\alpha_w)_w, (\beta_j)_j)$ для Glad и $\Gamma = (M^w)_w$ для DS.
 - М-шаг: Вычисляем $\hat{\Gamma} = \operatorname{argmax}_{\Gamma} \mathbb{E}_{P_{\text{post}}(z_j)} \log P(y_{ij} | \Gamma, z_j)$.
- Последнее время вошел в моду приближенный байесовский вывод.

Отказ от предположения об истинном лейбле

- Все существующие модели так или иначе основаны на предположении: существует детерминированный истинный лейбл. z_j .
- На практике много задач, когда у каждого работника свой правильный лейбл (релятивистский подход).
- В этих задачах бывают странные эффекты, когда $P_{post}(z_j = 1) \approx 1$, но мнения экспертов разделились примерно пополам.

Движение в сторону semi-supervised learning

- Точность агрегированных оценок зависит от ранней остановки
- Факторы заданий, работников и самого процесса оценивания могут нести дополнительный сигнал.