

Прикладная статистика 10. Логистическая регрессия.

8 ноября 2013 г.

Постановка


Задача: оценить влияние одного или нескольких признаков на наступление какого-либо события и оценить его вероятность.

$$(x_i, y_i), \quad x_i \in \mathbb{R}^k, \quad y_i \in \{0, 1\}, \quad i = 1, \dots, n;$$
$$\pi(x) = P(y = 1 | x) - ?$$

Пример 1

Разработка пестицидов: x_i — доза пестицида, y_i — смерть вредителя.

Повторяемый эксперимент с фиксированными уровнями фактора:




$$\hat{\pi}(x) = \frac{\sum_{i=1}^n y_i [x = x_i]}{\sum_{i=1}^n [x = x_i]}.$$

Пример 2

Эконометрика, построение кривой спроса: x_i — цена товара, y_i — согласие купить товар.

Неповторяемый эксперимент со случайными уровнями фактора:



Можно построить непараметрическую оценку при помощи ядерного сглаживания:

$$\hat{\pi}(x) = \frac{\sum_{i=1}^n y_i K\left(\frac{x-x_i}{h}\right)}{\sum_{i=1}^n K\left(\frac{x-x_i}{h}\right)}.$$

Параметризация

Линейная регрессия:

$$\pi(x) = \theta_0 + \theta_1 x + \varepsilon.$$

- Оценка вероятности может выходить за $[0, 1]$.
- В линейной регрессии $y = \mathbb{E}(y|x) + \varepsilon$, и МНК-оценка θ хороша, когда $\varepsilon \sim N(0, \sigma)$. Здесь же, если $y = \pi(x) + \varepsilon$, то $\varepsilon = 1 - \pi(x)$ или $\varepsilon = \pi(x)$, и МНК-оценка будет плохой.

Нужно такое нелинейное преобразование

$$g(\pi(x)) = \theta_0 + \theta_1 x + \varepsilon,$$

чтобы:


- $\hat{\pi}(x) = g^{-1}(\hat{\theta}_0 + \hat{\theta}_1 x)$ принимала значения из $[0, 1]$;
- изменения на краях диапазона значений x приводили к меньшим изменениям $\pi(x)$ (x — годовой доход, y — покупка автомобиля, $\pi(10000000 + 200000) - \pi(10000000) < \pi(500000 + 200000) - \pi(500000)$).

Параметризация

Logit:

$$g(\pi(x)) = \ln \frac{\pi(x)}{1 - \pi(x)} = \theta_0 + \theta_1 x + \varepsilon,$$

$$\hat{\pi}(x) = \frac{e^{\hat{\theta}_0 + \hat{\theta}_1 x}}{1 + e^{\hat{\theta}_0 + \hat{\theta}_1 x}}.$$



Относительный риск

Пусть $y \sim Ber(p)$, тогда **риск (odds)** события $y = 1$:

$$ODDS = \frac{p}{1 - p}.$$

Если $y_1 \sim Ber(p_1)$, $y_2 \sim Ber(p_2)$, то **относительный риск (odds ratio)** события $y_1 = 1$ по сравнению с событием $y_2 = 1$:

$$OR = \frac{p_1 / (1 - p_1)}{p_2 / (1 - p_2)}.$$

Серд. заболевания	Возраст	
	≥ 55	≤ 55
есть	21	22
нет	6	51

$$OR = \frac{21/6}{22/51} \approx 8.1.$$

Роль коэффициентов регрессии

$$\hat{y} = \hat{\theta}_0 + \hat{\theta}_1 x.$$

Пусть $x = [\text{возраст} \geq 55]$, $y = [\text{есть сердечные заболевания}]$. По $\hat{\theta}_1$ легко оценить относительный риск получения заболевания пожилыми людьми:

$$\widehat{OR} = e^{\hat{\theta}_1}.$$

Пусть $x = \text{возраст}$, $y = [\text{есть сердечные заболевания}]$. $e^{\hat{\theta}_1}$ имеет смысл мультипликативного прироста риска получения заболевания при увеличении возраста на 1 год.

Настройка параметров

$\pi(x)$ оценивает $P(y = 1 | x)$,

$1 - \pi(x)$ оценивает $P(y = 0 | x) \Rightarrow$

Вероятность $(x_i, 1) = \pi(x_i)$, $(x_i, 0) = 1 - \pi(x_i)$.

$$L(\theta) = \prod_{i=1}^n \pi(x_i)^{y_i} (1 - \pi(x_i))^{1-y_i},$$

$$LL(\theta) = - \sum_{i=1}^n (y_i \ln \pi(x_i) + (1 - y_i) \ln (1 - \pi(x_i))),$$

$$\hat{\theta} = \underset{\theta}{\operatorname{argmax}} LL(\theta).$$

$\hat{\theta}$ существует и единственна, находится методом Ньютона-Рафсона, является состоятельной и асимптотически эффективной оценкой θ , а также асимптотически нормальна.

Проблемы МП-оценки

$\hat{\theta}$ может не существовать или не быть конечной, если:

- наблюдения $y = 0$ и $y = 1$ линейно разделимы в пространстве признаков X ;
- матрица X вырождена.

Итерационный процесс может не сойтись, если число признаков k слишком велико относительно числа наблюдений n .

Дисперсия оценок

Пусть $I(\theta) \in \mathbb{R}^{(k+1) \times (k+1)}$ — матрица вторых производных $LL(\theta)$:

$$\frac{\partial^2 LL}{\partial \theta_j^2} = - \sum_{i=1}^n x_{ij}^2 \pi(x_i)(1 - \pi(x_i)),$$

$$\frac{\partial^2 LL}{\partial \theta_j \partial \theta_l} = - \sum_{i=1}^n x_{ij} x_{il} \pi(x_i)(1 - \pi(x_i)).$$

Другая форма записи:

$$I(\theta) = X^T V X,$$

$$V = \text{diag}(\pi(x_1)(1 - \pi(x_1)), \dots, \pi(x_n)(1 - \pi(x_n))).$$

Из теории оценок максимума правдоподобия: $\mathbb{D}\hat{\theta} = I^{-1}(\hat{\theta})$.

Доверительные интервалы

Для отдельного коэффициента θ_j :

$$\hat{\theta}_j \pm z_{1-\alpha/2} \sqrt{\left(I^{-1}(\hat{\theta}) \right)_{jj}}.$$

Для $g(x_0)$ — логита нового наблюдения x_0 :


$$x_0 \hat{\theta} \pm z_{1-\alpha/2} \sqrt{x_0^T I^{-1}(\hat{\theta}) x_0}.$$

Для вероятности $y = 1$ при $x = x_0$:

$$\left[\frac{e^{x_0 \hat{\theta} - z_{1-\alpha/2} \sqrt{x_0^T I^{-1}(\hat{\theta}) x_0}}}{1 + e^{x_0 \hat{\theta} - z_{1-\alpha/2} \sqrt{x_0^T I^{-1}(\hat{\theta}) x_0}}}, \frac{e^{x_0 \hat{\theta} + z_{1-\alpha/2} \sqrt{x_0^T I^{-1}(\hat{\theta}) x_0}}}{1 + e^{x_0 \hat{\theta} + z_{1-\alpha/2} \sqrt{x_0^T I^{-1}(\hat{\theta}) x_0}}} \right].$$

Критерий Вальда

нулевая гипотеза: $H_0: \theta_j = 0;$
 альтернатива: $H_1: \theta_j < \neq > 0;$
 статистика: $T = \frac{\hat{\theta}_j}{\sqrt{(I^{-1}(\hat{\theta}))_{jj}}};$
 $T \sim N(0, 1)$ при $H_0;$



достигаемый уровень значимости:

$$p(t) = \begin{cases} 1 - ncdf(t, 0, 1), & H_1: \theta_j > 0, \\ ncdf(t, 0, 1), & H_1: \theta_j < 0, \\ 2(1 - ncdf(|t|, 0, 1)), & H_1: \theta_j \neq 0. \end{cases}$$

Критерий, основанный на правдоподобии


$$X_{n \times (k+1)} = \begin{pmatrix} X_1 & X_2 \\ n \times (k+1-k_1) & n \times k_1 \end{pmatrix}; \quad \theta^T_{(k+1) \times 1} = \begin{pmatrix} \theta_1^T & \theta_2^T \end{pmatrix}^T_{(k+1-k_1) \times 1, k_1 \times 1};$$

нулевая гипотеза: $H_0: \theta_2 = 0;$

альтернатива: $H_1: H_0$ неверна;

статистика: $G = 2(LL_{ur} - LL_r);$

$G \sim \chi^2_{k_1}$ при $H_0;$



достигаемый уровень значимости:

$$p(g) = 1 - chi2cdf(g, k_1).$$

Значимость признаков

Поскольку распределение $\hat{\theta}$ нормально только асимптотически, точность критериев невысока.

Поэтому значимость признаков рекомендуется проверять на уровне $\alpha = 0.25$.

Пошаговая логистическая регрессия

- **Шаг 0.** Настраивается модель с одной только константой, а также все модели с одной переменной. Рассчитывается статистика Вальда каждой модели и достигаемый уровень значимости. Выбирается модель с наименьшим достигаемым уровнем значимости.
Соответствующая переменная X_{e1} включается в модель, если этот достигаемый уровень значимости меньше порогового значения $p_E = 0.15$.
- **Шаг 1.** Рассчитывается статистика Вальда и достигаемый уровень значимости для всех моделей, содержащих две переменные, одна из которых X_{e1} . Аналогично принимается решение о включении X_{e2} .
- **Шаг 2.** Если была добавлена переменная X_{e2} , возможно, X_{e1} уже не нужна. В общем случае просчитываются все возможные варианты исключения одной переменной, рассматривается вариант с наибольшим достигаемым уровнем значимости, соответствующая переменная исключается, если он превосходит пороговое значение $p_R = 0.2$.
- ...

Мультиколлинеарность

Признаки мультиколлинеарности:

- правдоподобие модели высоко, но оценки многих коэффициентов близки к своим стандартным отклонениям;
- коэффициенты сильно меняются при включении и исключении других признаков.

Порог классификации

Как по $\pi(x)$ оценить y ?

$$y = [\pi(x) \geq p_0].$$

Чаще всего берут $p_0 = 0.5$, но можно выбирать по другим критериям, например, для достижения заданных показателей чувствительности или специфичности.


Пример

Эффективность терапии для наркозависимых, $p_0 = 0.5$:

\hat{y}	y	1	0
1		16	11
0		131	417

Чувствительность: $\frac{16}{16+131} \approx 10.9\%$.

Специфичность: $\frac{417}{11+417} \approx 97.4\%$.



Прикладная статистика
10. Логистическая регрессия.

Рябенко Евгений
riabenko.e@gmail.com