

Точечное оценивание параметров: ММП и МНК

Лекция №6

Статистические методы в ядерном эксперименте, ИЯФ, 2024 г.

- 1 Метод максимального правдоподобия (ММП)
- 2 Метод наименьших квадратов (МНК)

Метод максимального правдоподобия (I)

ММП представляет собой технику оценки значений параметров распределений на основе конечного набора данных.

ММП также позволяет найти ошибки полученных оценок.

Идея метода состоит в том, что в качестве оценки параметра θ нужно взять такое его значение, которое максимизирует вероятность получения уже имеющейся выборки $\{X_k\}_n$.

Функцией правдоподобия (ФП) $F(\vec{X}; \theta)$ для выборки дискретной/непрерывной с.в. называется функция:

$$F(\vec{X}; \theta) = \begin{cases} P(x = X_1; \theta) \cdot \dots \cdot P(x = X_n; \theta) \\ f(X_1; \theta) \cdot \dots \cdot f(X_n; \theta) \end{cases} = \begin{cases} \prod_{i=1}^n P(x = X_i; \theta) \\ \prod_{i=1}^n f(X_i; \theta) \end{cases}$$

где $f(x; \theta)$ – ф.п.в. непрерывной с.в.

Таким образом, ФП в дискретном случае есть вероятность реализации наблюдаемой выборки $\{X_k\}_n$. В непрерывном случае ФП есть совместная плотность вероятности n -мерного случайного вектора выборки.

Логарифмической функцией правдоподобия (ЛФП) $\mathcal{L}(\vec{X}; \theta)$ называется функция:

$$\mathcal{L}(\vec{X}; \theta) = \ln F(\vec{X}, \theta) = \sum_{k=1}^n f(X_k; \theta)$$

Оценкой максимального правдоподобия θ^* для параметра θ называется такое значение θ , при котором достигается максимум (Л)ФП.

Замечание: Так как функция $y = \ln x$ строго монотонна, то экстремум функции $\mathcal{L}(\vec{X}; \theta)$ достигается в той же точке θ^* , что и для $F(\vec{X}, \theta)$:

$$\left. \frac{\partial \mathcal{L}}{\partial \theta} \right|_{\theta=\theta^*} = 0 \text{ – условие экстремума}$$

$$\left. \frac{\partial^2 \mathcal{L}}{\partial \theta^2} \right|_{\theta=\theta^*} < 0 \text{ – условие максимума}$$

Замечание: Статистика $f_{\theta}(X_1, \dots, X_n)$ называется достаточной относительно параметра θ , если она содержит в себе всю информацию о параметре θ , которая может быть получена на основе заданной выборки $\{X_k\}_n$.

Пример 1: Пусть $\{X_k\}_n$ выборка из распределения Бернулли с параметром ρ . Найдём оценку ρ^* параметра ρ методом МП.

Пример 2: Пусть $\{X_k\}_n$ выборка из распределения Пуассона с параметром μ . Найдём оценку μ^* параметра μ методом МП.

Пример 3: Пусть $\{X_k\}_n$ выборка из распределения $\gamma(a, b)$. Найдём оценки параметров a и b методом МП.

Пример 4: Пусть $\{X_k\}_n$ выборка из распределения $N(\mu; \sigma)$. Найдём оценки параметров μ и σ методом МП.

Метод максимального правдоподобия (IV)

Свойства оценок методом МП:

- Если существует достаточная оценка, то ММП дает именно её и тем самым исчерпывает всю имеющуюся информацию. Таким образом, оценка ММП является эффективной в своем классе.

Эффективность

Статистика $\theta^* = \theta^*(X_1, \dots, X_n)$ называется эффективной оценкой параметра θ в некотором классе состоятельных оценок, если она не хуже в среднеквадратичном смысле $E((\theta^* - \theta)^2) \leq E((\theta_1^* - \theta)^2)$.

- Оценка θ^* ММП является асимптотически нормальной со средним θ (т.е. асимптотически несмещённой) и дисперсией $D(\theta) = -1/E\left(\frac{\partial^2 \mathcal{L}(\vec{X}, \theta)}{\partial \theta^2}\right)$.
- Оценка ММП инвариантна относительно преобразований оцениваемого параметра. То есть, если $g = g(\theta)$, то $g^* = g(\theta^*)$. Так, если $s^2 = \frac{1}{n} \sum_{k=1}^n (X_k - \langle X \rangle)^2$ есть оценка ММП для дисперсии σ^2 , то оценкой ММП для среднеквадратичного отклонения $\sigma = \sqrt{\sigma^2}$ будет просто $s = \sqrt{s^2}$.
- Фактором, ограничивающим применимость ММП, является необходимость знания ф.п.в. для построения функции правдоподобия. Поэтому ММП дает лишь лучшее значение параметра уже выбранной модели (ф.п.в.).

Метод максимального правдоподобия (V)

Пример 5: Пусть имеется n независимых и нормально распределенных результатов измерений Y_k некоторой величины y , истинное (неизвестное) значение которой есть θ , а σ_k^2 – соответствующие известные дисперсии. Провести усреднение результатов этих измерений, используя ММП.

Функция правдоподобия для статистики $\{Y_k\}_n$ будет:

$$F(\vec{Y}; \theta) = \prod_{k=1}^n \frac{1}{\sqrt{2\pi}\sigma_k} e^{-\frac{(Y_k - \theta)^2}{2\sigma_k^2}}$$

$$\mathcal{L}(\vec{Y}; \theta) = \ln F(\vec{Y}; \theta) = - \left[\frac{n}{2} \ln 2\pi + \sum_{k=1}^n \ln \sigma_k \right] - \frac{1}{2} \sum_{k=1}^n \frac{(Y_k - \theta)^2}{\sigma_k^2}$$

$$\frac{\partial \mathcal{L}}{\partial \theta} = \sum_{k=1}^n \frac{(Y_k - \theta)}{\sigma_k^2} = 0 \Rightarrow \theta^* = \frac{\sum_{k=1}^n Y_k}{\sum_{k=1}^n 1/\sigma_k^2}$$

$$\frac{\partial^2 \mathcal{L}}{\partial \theta^2} = - \sum_{k=1}^n \frac{1}{\sigma_k^2} \Rightarrow D(\theta^*) = \left(\sum_{k=1}^n \frac{1}{\sigma_k^2} \right)^{-1}$$

Если $\sigma_k = \sigma$ (одинаковая точность), то получаем ожидаемый результат: $\theta^* = \langle y \rangle$, $\sigma_\theta = \sigma/\sqrt{n}$.

В предыдущем примере фактически минимизировалась функция

$$\tilde{\mathcal{L}}(\vec{Y}; \theta) = \sum_{k=1}^n \frac{(Y_k - \theta)^2}{\sigma_k^2},$$
 равная сумме квадратов отклонений

измеренных значений от истинных значений функции, но отклонения берутся в единицах стандартных отклонений. Это одна из реализаций т.н. метода наименьших квадратов (МНК).

Первой работой, в которой использовался МНК, является работа Лежандра 1805 г., в которой метод применялся для определения параметров орбит комет.

Возможны и другие критерии оптимизации, в результате получим другие оценки параметров.

Так, в 1792 г. Лаплас применял критерий, согласно которому наименьшее значение должна принимать сумма абсолютных значений, а не квадратов отклонений.

В 1831 г. Коши предложил метод, в котором требовалось, чтобы наибольшее из всех отклонений (по абсолютной величине) было минимальным. Этот принцип минимакса применяется и по сей день.

Метод наименьших квадратов (II)

Пусть наблюдаемая случайная величина Y зависит от случайной величины X , $Y = Y(X; \vec{\theta})$. Значения величины X мы наблюдаем или задаем. Обозначим через $f(t; \vec{\theta})$ функцию, отражающую зависимость среднего значения величины Y от значения X , $E(Y(X = t; \theta)) = f(t; \vec{\theta})$. Функция $f(t; \vec{\theta})$ называется линией регрессии Y на X .

В результате n измерений, в которых X принимает набор значений t_1, t_2, \dots, t_n , получим значения y_1, y_2, \dots, y_n . Рассмотрим случай линейной зависимости Y от оцениваемых параметров $\vec{\theta}$:

$$f(t; \vec{\theta}) = \theta_1 g_1(t) + \dots + \theta_m g_m(t)$$

Тогда в общем случае можно записать: $y_k = f(t_k; \vec{\theta}) + \varepsilon_k$, где ε_k – случайные отклонения, такие что $E(\varepsilon_k) = 0$ и $D(\varepsilon_k) = \sigma_k^2$.

Найдём оценку вектора параметров $\vec{\theta}$ из условия минимума квадратичной формы S , которая в общем случае наличия корреляций между величинами y_k , имеет вид:

$$S = \sum_{i,j=1}^n (y_i - f(t_i; \vec{\theta})) D_{ij}^{-1} (y_j - f(t_j; \vec{\theta})),$$

где D_{ij} – ковариационная матрица случайной величины y_k .

Используем обозначения:

$$\vec{y} = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}, \vec{\varepsilon} = \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}, \vec{\theta} = \begin{pmatrix} \theta_1 \\ \vdots \\ \theta_m \end{pmatrix}, \hat{G} = \begin{pmatrix} g_1(t_1) & \cdots & g_m(t_1) \\ \vdots & \ddots & \vdots \\ g_1(t_n) & \cdots & g_m(t_n) \end{pmatrix}$$

Тогда:

$$\vec{y} = \hat{G}\vec{\theta} + \vec{\varepsilon}, \quad \vec{\varepsilon} = \vec{y} - \hat{G}\vec{\theta}, \quad S = \vec{\varepsilon}^\dagger D^{-1} \vec{\varepsilon} = (\vec{y} - \hat{G}\vec{\theta})^\dagger D^{-1} (\vec{y} - \hat{G}\vec{\theta})$$

$$\delta S = 2\delta\vec{\theta}^\dagger (\hat{G}^\dagger D^{-1} \hat{G}\vec{\theta} - \hat{G}^\dagger D^{-1} \vec{y}) = 0, \quad \hat{G}^\dagger D^{-1} \hat{G}\vec{\theta} = \hat{G}^\dagger D^{-1} \vec{y},$$

$$\hat{B} = \hat{G}^\dagger D^{-1} \hat{G}, \quad \hat{B} = \hat{B}^\dagger \Rightarrow \vec{\theta}^* = \hat{B}^{-1} \hat{G}^\dagger D^{-1} \vec{y}$$

$$D(\vec{\theta}^*) = E((\vec{\theta}^* - E(\vec{\theta}^*))(\vec{\theta}^* - E(\vec{\theta}^*))^\dagger) =$$

$$E(\hat{B}^{-1} \hat{G}^\dagger D^{-1} (\vec{y} - E(\vec{y})) (\vec{y} - E(\vec{y}))^\dagger D^{-1} \hat{G} \hat{B}^{-1}) =$$

$$= \hat{B}^{-1} \hat{G}^\dagger D^{-1} E((\vec{y} - E(\vec{y})) (\vec{y} - E(\vec{y}))^\dagger) D^{-1} \hat{G} \hat{B}^{-1} = \hat{B}^{-1} \hat{G}^\dagger D^{-1} D D^{-1} \hat{G} \hat{B}^{-1} =$$

$$= \hat{B}^{-1} \Rightarrow D(\vec{\theta}^*) = \hat{B}^{-1}$$

Метод наименьших квадратов (IV)

Пример 1: Пусть $f(t; \vec{\theta}) = \theta_1 + \theta_2 t$ и $\{y_k\}$ независимы. Найдём θ_1^* и θ_2^* методом наименьших квадратов.

$$\vec{y} = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}, \vec{\theta} = \begin{pmatrix} \theta_1 \\ \theta_2 \end{pmatrix}, \hat{G} = \begin{pmatrix} 1 & t_1 \\ \vdots & \vdots \\ 1 & t_n \end{pmatrix}, D = \begin{pmatrix} \sigma_1^2 & 0 & \cdots & 0 \\ 0 & \sigma_2^2 & \cdots & 0 \\ \cdot & \cdot & \ddots & 0 \\ 0 & 0 & \cdots & \sigma_n^2 \end{pmatrix}$$

$$D^{-1} = \begin{pmatrix} \sigma_1^{-2} & 0 & \cdots & 0 \\ 0 & \sigma_2^{-2} & \cdots & 0 \\ \cdot & \cdot & \ddots & 0 \\ 0 & 0 & \cdots & \sigma_n^{-2} \end{pmatrix}, \hat{B} = \hat{G}^\dagger D^{-1} \hat{G} = \begin{pmatrix} \sum_{i=1}^n \frac{1}{\sigma_i^2} & \sum_{i=1}^n \frac{t_i}{\sigma_i^2} \\ \sum_{i=1}^n \frac{t_i}{\sigma_i^2} & \sum_{i=1}^n \frac{t_i^2}{\sigma_i^2} \end{pmatrix}$$

$$\hat{B}^{-1} = \frac{1}{\det \hat{B}} \begin{pmatrix} \sum_{i=1}^n \frac{t_i^2}{\sigma_i^2} & -\sum_{i=1}^n \frac{t_i}{\sigma_i^2} \\ -\sum_{i=1}^n \frac{t_i}{\sigma_i^2} & \sum_{i=1}^n \frac{1}{\sigma_i^2} \end{pmatrix}, \det \hat{B} = \left(\sum_{i=1}^n \frac{1}{\sigma_i^2} \right) \left(\sum_{i=1}^n \frac{t_i^2}{\sigma_i^2} \right) - \left(\sum_{i=1}^n \frac{t_i}{\sigma_i^2} \right)^2$$

$$\det \hat{B} = \left(\sum_{i=1}^n \frac{1}{\sigma_i^2} \right)^2 (\langle t^2 \rangle - \langle t \rangle^2) = \left(\sum_{i=1}^n \frac{1}{\sigma_i^2} \right) \left(\sum_{i=1}^n \frac{(t_i - \langle t \rangle)^2}{\sigma_i^2} \right), \langle t \rangle = \sum_{i=1}^n \frac{t_i}{\sigma_i^2} / \sum_{i=1}^n \frac{1}{\sigma_i^2}$$

$$\theta_1^* = \frac{1}{\det \hat{B}} \left(\left(\sum_{i=1}^n \frac{y_i}{\sigma_i^2} \right) \left(\sum_{i=1}^n \frac{t_i^2}{\sigma_i^2} \right) - \left(\sum_{i=1}^n \frac{t_i}{\sigma_i^2} \right) \left(\sum_{i=1}^n \frac{t_i y_i}{\sigma_i^2} \right) \right) = \frac{\langle y \rangle \langle t^2 \rangle - \langle t \rangle \langle ty \rangle}{\langle t^2 \rangle - \langle t \rangle^2}$$

$$\theta_2^* = \frac{1}{\det \hat{B}} \left(\left(\sum_{i=1}^n \frac{1}{\sigma_i^2} \right) \left(\sum_{i=1}^n \frac{t_i y_i}{\sigma_i^2} \right) - \left(\sum_{i=1}^n \frac{t_i}{\sigma_i^2} \right) \left(\sum_{i=1}^n \frac{y_i}{\sigma_i^2} \right) \right) = \frac{\langle ty \rangle - \langle t \rangle \langle y \rangle}{\langle t^2 \rangle - \langle t \rangle^2}$$

Метод наименьших квадратов (V)

Пример 2: В предыдущем примере θ_1^* и θ_2^* оказались коррелированными ($(\hat{B}^{-1})_{12} \neq 0$). Если ввести $f(t; \vec{\omega}) = \omega_1 + \omega_2(t - \langle t \rangle)$, где $\omega_1 = \theta_1 + \theta_2 \langle t \rangle$ и $\omega_2 = \theta_2$, $\langle t \rangle = \frac{\sum_{i=1}^n t_i}{\sum_{i=1}^n 1}$, то:

$$\vec{\omega} = \begin{pmatrix} \omega_1 \\ \omega_2 \end{pmatrix} = \begin{pmatrix} 1 & \langle t \rangle \\ 0 & 1 \end{pmatrix} \begin{pmatrix} \theta_1 \\ \theta_2 \end{pmatrix} = \hat{A} \vec{\theta} \Rightarrow \vec{\omega}^* = \hat{A} \vec{\theta}^*$$

$$\omega_1^* = \langle y \rangle = \frac{\sum_{i=1}^n y_i}{\sum_{i=1}^n 1}$$

$$\omega_2^* = \frac{\langle ty \rangle - \langle t \rangle \langle y \rangle}{\langle t^2 \rangle - \langle t \rangle^2} = \frac{\langle y(t - \langle t \rangle) \rangle}{\langle (t - \langle t \rangle)^2 \rangle} = \frac{\sum_{i=1}^n y_i (t_i - \langle t \rangle)}{\sum_{i=1}^n (t_i - \langle t \rangle)^2}$$

$$D(\vec{\omega}^*) = E((\vec{\omega} - \vec{\omega}^*)(\vec{\omega} - \vec{\omega}^*)^\dagger) = \hat{A} E((\vec{\theta} - \vec{\theta}^*)(\vec{\theta} - \vec{\theta}^*)^\dagger) \hat{A}^\dagger = \hat{A} \hat{B}^{-1} \hat{A}^\dagger$$

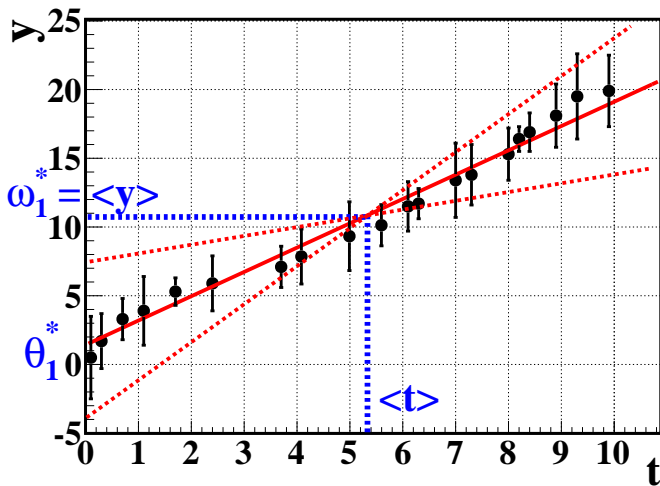
$$\hat{B}^{-1} = \frac{\Sigma^2}{\Delta_t^2} \begin{pmatrix} \langle t^2 \rangle & -\langle t \rangle \\ -\langle t \rangle & 1 \end{pmatrix}, \quad \Sigma^2 = \left(\sum_{i=1}^n 1/\sigma_i^2 \right)^{-1}, \quad \Delta_t^2 = \langle t^2 \rangle - \langle t \rangle^2$$

$$D(\vec{\omega}^*) = \frac{\Sigma^2}{\Delta_t^2} \begin{pmatrix} 1 & \langle t \rangle \\ 0 & 1 \end{pmatrix} \begin{pmatrix} \langle t^2 \rangle & -\langle t \rangle \\ -\langle t \rangle & 1 \end{pmatrix} \begin{pmatrix} 1 & 0 \\ \langle t \rangle & 1 \end{pmatrix} = \begin{pmatrix} \Sigma^2 & 0 \\ 0 & \frac{\Sigma^2}{\Delta_t^2} \end{pmatrix}$$

Параметры ω_1^* и ω_2^* некоррелированы.

Метод наименьших квадратов (VI)

Таким образом при линейной аппроксимации искомая прямая всегда проходит через точку $(\langle t \rangle, \langle y \rangle)$. Причём параметр $\omega_1^* = \langle y \rangle$ не меняется при вариации параметра ω_2^* (наклона прямой).



Рассмотрим случай, когда величина $y = f(t; \vec{\theta})$ есть произвольная функция параметров $\vec{\theta}$. Тогда, если $\vec{\theta}'$ есть некоторое достаточно хорошее начальное приближение к истинному значению $\vec{\theta}^*$, то:

$$f(t_i; \vec{\theta}) = f(t_i; \vec{\theta}') + \nabla f(t_i; \vec{\theta}')(\vec{\theta} - \vec{\theta}') + \mathcal{O}((\vec{\theta} - \vec{\theta}')^2)$$

Таким образом, линеаризуя зависимость y от искомых параметров $\vec{\theta}$ становится возможным применить МНК. При этом оптимальное значение $\vec{\theta}_1^*$, найденное после первой итерации МНК, используются снова в качестве нового, более точного, приближения $\vec{\theta}'$ и процедура повторяется.

На некотором шаге отличие новых оптимальных значений $\vec{\theta}^*$ от входных значений $\vec{\theta}'$ становится меньше наперед заданного малого ε , и процедура определения $\vec{\theta}^*$ считается завершённой.

Метод наименьших квадратов (VIII)

Оценки параметров, полученные МНК, обладают следующими свойствами, независящими от вида распределения величин

$\vec{\varepsilon} = \vec{y} - \hat{G}\vec{\theta}$, при условиях, что $E(\varepsilon_k) = 0$, $D(\varepsilon_k) < \infty$ и ε_k независимы:

- $\vec{\theta}^*$ является несмещенной оценкой вектора параметров $\vec{\theta}$.
- В классе несмещённых оценок, линейных по \vec{y} , $\vec{\theta}^*$ является эффективной оценкой.
- Если $D(\varepsilon_k) = \sigma^2 \forall k$, то для остаточной суммы квадратов R имеем:

$$R = (\vec{y} - \hat{G}\vec{\theta}^*)^\dagger (\vec{y} - \hat{G}\vec{\theta}^*), \quad E(R) = \sigma^2(n - m),$$

т.е. остаточную сумму квадратов R можно использовать для оценки дисперсии ε_k : $\sigma^{2*} = R/(n - m)$, где m —число параметров $\vec{\theta}^*$, определяемых из минимизации.

- Если же σ^2 известна, то величина $R/(\sigma^2(n - m))$ (ее близость к 1) может быть использована как характеристика "качества" аппроксимации (с помощью критерия согласия χ^2).