

Maximum likelihood-metoden Skattningarna $(\theta_1)_{\text{obs}}^*, \dots, (\theta_r)_{\text{obs}}^*$ är de värden på $\theta_1, \dots, \theta_r$ som maximerar *trolighetsfunktionen*

$$L(\theta_1, \dots, \theta_r) = f_{X_1, \dots, X_n}(x_1, \dots, x_n)$$

vid kontinuerliga fördelningar, eller

$$L(\theta_1, \dots, \theta_r) = \mathbf{P}(X_1 = x_1, \dots, X_n = x_n)$$

vid diskreta.

Filosofin bakom Maximum likelihood-metoden är att vårt utfall (stickprovet) bestäms av parametrarna i de ingående fördelningarna. Skattningen av dessa parametrar är de värden som gör det observerade så troligt som möjligt.

Tips! Ofta är det enklare att maximera $\log L(\theta_1, \dots, \theta_r)$.

Exempel: Binomialfördelningen. Låt x vara ett utfall av en binomialfördelad stokastisk variabel X .

$$L(p) = \mathbf{P}(X = x) = \binom{n}{x} p^x (1-p)^{n-x}.$$

Logaritmering ger

$$\ln L(p) = \ln \left(\binom{n}{x} \right) + x \ln p + (n-x) \ln(1-p).$$

Derivering bestämmer maximum:

$$\frac{d}{dp} \ln L(p) = 0 + x \frac{1}{p} - (n-x) \frac{1}{1-p} = 0$$

ger lösningen $p = x/n$. Alltså, ML-skattningen av p är $p_{\text{obs}}^* = x/n$.

Minsta kvadrat-metoden Låt x_1, \dots, x_n vara utfall av oberoende stokastiska variabler X_1, \dots, X_n (med samma varians). Skattningarna $(\theta_1)_{\text{obs}}^*, \dots, (\theta_r)_{\text{obs}}^*$ de värden på $\theta_1, \dots, \theta_r$ som minimerar *minsta kvadrat-avstånden* mellan observationer och väntevärden:

$$Q(\theta_1, \dots, \theta_r) = \sum_{i=1}^n (x_i - \mathbf{E}[X_i])^2.$$

Även här minimeras Q oftast med hjälp av derivering.

Exempel: Låt x vara ett utfall av en binomialfördelad stokastisk variabel X . MK-metoden: finn p som minimerar

$$Q(p) = (x - \mathbf{E}[X])^2 = (x - np)^2.$$

Eftersom $Q(p) \geq 0$ med likhet om $p = x/n$ är MK-skattningen av p , $p_{\text{obs}}^* = x/n$.

Konfidensintervall

Definition: Ett konfidensintervall $I_\theta(x_1, \dots, x_n)$ för θ är ett utfall av ett stokastiskt intervall $I_\theta(X_1, \dots, X_n)$ sådant att

$$\mathbf{P}(\theta \in I_\theta(X_1, \dots, X_n)) = 1 - \alpha = \text{konfidensgraden}.$$

Låt θ_{obs}^* vara en skattning av θ sådan att θ^* är $N(\theta, D)$. Då kan vi ur $N(0, 1)$ -tabeller bestämma kvantiler $\lambda_{\alpha/2}$ så att med sannolikhet $1 - \alpha$ är

$$-\lambda_{\alpha/2} \leq \frac{\theta^* - \theta}{D} \leq \lambda_{\alpha/2}$$

eller

$$-\lambda_{\alpha/2}D \leq \theta^* - \theta \leq \lambda_{\alpha/2}D$$

eller

$$\theta^* - \lambda_{\alpha/2}D \leq \theta \leq \theta^* + \lambda_{\alpha/2}D.$$

Det vill säga

$$\theta \in \theta_{\text{obs}}^* \pm \lambda_{\alpha/2}D$$

är ett *konfidsensintervall* för θ med konfidsensgrad $1 - \alpha$.

Om θ^* är approximativt $N(\theta, D)$ där $D = D(\theta^*)$ inte är känd får den skattas och

$$\theta \in \theta_{\text{obs}}^* \pm \lambda_{\alpha/2}d(\theta^*)$$

är ett (approximativt) konfidsensintervall för θ med konfidsensgrad $\approx 1 - \alpha$.

Exempel: Låt x_1, \dots, x_n vara utfall av oberoende $N(\mu, \sigma)$ -fördelade stokastiska variabler X_1, \dots, X_n .

Väntevärdet μ skattas med \bar{x} där

$$\bar{X} \text{ är } N(\mu, \sigma/\sqrt{n})$$

Ett konfidsensintervall för μ är

$$\mu \in \bar{x} \pm \lambda_{\alpha/2} \frac{\sigma}{\sqrt{n}} \quad (1 - \alpha)$$

Exempel: Opinionsundersökning. Låt x vara antalet sympatisörer av n intervjuade. Vi modellerar x som ett utfall av en binomialfördelad stokastisk variabel X , X är $\text{Bin}(n, p)$.

Då är $p_{\text{obs}}^* = x/n$ och $D(p^*) = \sqrt{p(1-p)/n}$. Om p^* är approximativt $N(p, D(p^*))$ så fås ($\approx 95\%$)-konfidsensintervall

| Parti | Antal, x | Andel [%], p_{obs}^* | Medelfel [%], $d(p^*)$ | $p_{\text{obs}}^* \pm 1.96d(p^*)$ |
|-------|------------|-------------------------------|------------------------|-----------------------------------|
| (S) | 668 | 35.0 | 1.1 | (32.9, 37.2) |
| (V) | 139 | 7.3 | 0.6 | (6.1, 8.5) |
| (Mp) | 109 | 5.7 | 0.5 | (4.7, 6.8) |
| (M) | 463 | 24.3 | 1.0 | (22.4, 26.2) |
| (C) | 126 | 6.6 | 0.6 | (5.5, 7.7) |
| (Fp) | 244 | 12.8 | 0.8 | (11.3, 14.3) |
| (Kd) | 101 | 5.3 | 0.5 | (4.3, 6.3) |
| Övr | 57 | 3.0 | 0.4 | (2.2, 3.8) |
| | 1907 | | | |

Normalapproximationen motiveras av att skattningen av

$$V(X) = np(1-p)$$

alla är mycket större än 10.

Exakta konfidsensintervall i normalfördelningen

Låt x_1, \dots, x_n vara utfall av oberoende $N(\mu, \sigma)$ -fördelade stokastiska variabler X_1, \dots, X_n .

Fördelningen för

$$\frac{1}{\sigma^2} \sum_{i=1}^n (X_i - \mu)^2 = \sum_{i=1}^n \left(\frac{X_i - \mu}{\sigma} \right)^2 = \sum_{i=1}^n Z_i^2$$

är fördelningen för en summa av kvadrater av oberoende $N(0, 1)$ -variabler, och beror inte på μ eller σ . Fördelningen kallas χ^2 -fördelningen och parametern, antalet termer i summan, kallas dess frihetsgrader. Fördelningen finns tabulerad i formelsamlingen.

Sats. Man kan visa att

$$\frac{(n-1)S^2}{\sigma^2} = \frac{1}{\sigma^2} \sum_{i=1}^n (X_i - \bar{X})^2$$

är $\chi^2(n-1)$ -fördelad (och oberoende av \bar{X}).

Vi kan således för varje sannolikhet α bestämma kvantilerna $\chi_{1-\alpha/2}^2$ och $\chi_{\alpha/2}^2$ så att

$$P\left(\chi_{1-\alpha/2}^2 \leq \frac{(n-1)S^2}{\sigma^2} \leq \chi_{\alpha/2}^2\right) = 1 - \alpha.$$

Så med sannolikhet $1 - \alpha$ är

$$\chi_{1-\alpha/2}^2 \leq \frac{(n-1)S^2}{\sigma^2} \leq \chi_{\alpha/2}^2$$

eller

$$\frac{(n-1)S^2}{\chi_{\alpha/2}^2} \leq \sigma^2 \leq \frac{(n-1)S^2}{\chi_{1-\alpha/2}^2}.$$

Detta är ger att

$$\frac{(n-1)s^2}{\chi_{\alpha/2}^2} \leq \sigma^2 \leq \frac{(n-1)s^2}{\chi_{1-\alpha/2}^2}.$$

är ett [symmetriskt] konfidensintervall för σ^2 med konfidensgrad $1 - \alpha$. Ett intervall för σ är

$$\sqrt{\frac{(n-1)s^2}{\chi_{\alpha/2}^2}} \leq \sigma \leq \sqrt{\frac{(n-1)s^2}{\chi_{1-\alpha/2}^2}}.$$

Vidare så är

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$$

och

$$\frac{\bar{X} - \mu}{S/\sqrt{n}} \text{ är } t(n-1)\text{-fördelad,}$$

alltså, storheten har en fördelning som inte beror på μ eller σ utan bara på antalet observationer n . Utnyttjar vi tabellerna för t -fördelningen kan vi för varje sannolikhet α bestämma kvantiler $t_{\alpha/2}$ så att med sannolikhet $1 - \alpha$ är

$$-t_{\alpha/2} \leq \frac{\bar{X} - \mu}{S/\sqrt{n}} \leq t_{\alpha/2}$$

eller

$$-t_{\alpha/2} \frac{S}{\sqrt{n}} \leq \bar{X} - \mu \leq t_{\alpha/2} \frac{S}{\sqrt{n}}$$

eller

$$\bar{X} - t_{\alpha/2} \frac{S}{\sqrt{n}} \leq \mu \leq \bar{X} + t_{\alpha/2} \frac{S}{\sqrt{n}}.$$

Alltså, ett [symmetriskt] konfidensintervall för μ med konfidensgrad $1 - \alpha$ är

$$\mu \in \bar{x} \pm t_{\alpha/2} \frac{s}{\sqrt{n}}.$$