

Matematisk statistik

KTH

Formel- och tabellsamling i matematisk statistik

1. Stokastiska variabler

$$V(X) = E(X^2) - (E(X))^2$$

$$C(X, Y) = E((X - E(X))(Y - E(Y))) = E(XY) - E(X)E(Y)$$

$$\rho(X, Y) = \frac{C(X, Y)}{D(X)D(Y)}$$

Gauss' approximationsformler

Med beteckningar och förutsättningar enligt läroboken gäller

a) $E(g(X)) \approx g(E(X))$

$$V(g(X)) \approx V(X)[g'(E(X))]^2$$

b) $E(g(X_1, \dots, X_n)) \approx g(m_1, \dots, m_n)$

$$V(g(X_1, \dots, X_n)) \approx \sum_{i=1}^n V(X_i) \left(\frac{\partial g}{\partial m_i} \right)^2 + 2 \sum_{i < j} C(X_i, X_j) \cdot \frac{\partial g}{\partial m_i} \frac{\partial g}{\partial m_j}$$

2. Diskreta fördelningar

Binomialfördelningen

X är $\text{Bin}(n, p)$ om $p_X(k) = \binom{n}{k} p^k (1-p)^{n-k}$, $k = 0, 1, \dots, n$, där $0 < p < 1$

$$E(X) = np, \quad V(X) = np(1-p)$$

”För-första-gången”-fördelningen

X är $\text{ffg}(p)$ om $p_X(k) = p(1-p)^{k-1}$, $k = 1, 2, 3, \dots$, där $0 < p < 1$

$$E(X) = \frac{1}{p}, \quad V(X) = \frac{1-p}{p^2}$$

Hypergeometriska fördelningen

X är $\text{Hyp}(N, n, p)$ om $p_X(k) = \frac{\binom{Np}{k} \binom{N(1-p)}{n-k}}{\binom{N}{n}}$, där N , Np och n är positiva heltal samt $0 < p < 1$

$$E(X) = np, \quad V(X) = \frac{N-n}{N-1} \cdot np(1-p)$$

Poissonfördelningen

X är $\text{Po}(m)$ där $m > 0$ om $p_X(k) = \frac{m^k}{k!} \cdot e^{-m}$, $k = 0, 1, 2, \dots$

$$E(X) = m, \quad V(X) = m$$

3. Kontinuerliga fördelningar

Likformig fördelning (Rektangelfördelning)

$$X \text{ är } R(a, b) \text{ där } a < b \text{ om } f_X(x) = \begin{cases} \frac{1}{b-a} & \text{för } a \leq x \leq b \\ 0 & \text{annars} \end{cases}$$

$$E(X) = \frac{a+b}{2}, \quad V(X) = \frac{(b-a)^2}{12}$$

Exponentialfördelningen

$$X \text{ är } \text{Exp}(m) \text{ där } m > 0 \text{ om } f_X(x) = \begin{cases} \frac{1}{m} \cdot e^{-x/m} & \text{för } x > 0 \\ 0 & \text{annars} \end{cases}$$

$$E(X) = m, \quad V(X) = m^2$$

Normalfördelningen

$$X \text{ är } N(m, \sigma^2) \text{ om } f_X(x) = \frac{1}{\sqrt{2\pi} \cdot \sigma} \cdot e^{-\frac{(x-m)^2}{2\sigma^2}}, \quad -\infty < x < \infty, \quad \sigma > 0$$

$$E(X) = m, \quad V(X) = \sigma^2$$

Antag att $Z = \frac{X-m}{\sigma}$. Då gäller:

X är $N(m, \sigma^2)$ om och endast om Z är $N(0, 1)$.

Om Z är $N(0, 1)$ så har Z fördelningsfunktionen $\Phi(x)$ enligt tabell 1 och tätighetsfunktionen $\varphi(x) = \frac{1}{\sqrt{2\pi}} \cdot e^{-x^2/2}, \quad -\infty < x < \infty$

En linjär sammansättning $\sum a_i X_i$ av oberoende, normalfördelade stokastiska variabler är normalfördelad.

4. Centrala gränsvärdessatsen

Om X_1, X_2, \dots, X_n är oberoende likafördelade stokastiska variabler med väntevärde m och standardavvikelse $\sigma > 0$ så är $Y_n = X_1 + \dots + X_n$ approximativt $N(nm, \sigma\sqrt{n})$ om n är stort.

5. Approximation

$$\text{Hyp}(N, n, p) \sim \text{Bin}(n, p) \text{ om } \frac{n}{N} \leq 0.1$$

$$\text{Bin}(n, p) \sim \text{Po}(np) \text{ om } p \leq 0.1$$

$$\text{Bin}(n, p) \sim N(np, \sqrt{np(1-p)}) \text{ om } np(1-p) \geq 10$$

$$\text{Po}(m) \sim N(m, \sqrt{m}) \text{ om } m \geq 15$$

6. Tjebysjovs olikhet

Om $E(X) = m$ och $D(X) = \sigma^2 > 0$ så gäller för varje $k > 0$ att

$$P(|X - m| > k\sigma) \leq \frac{1}{k^2}$$

7. Statistiskt material

$$\bar{x} = \frac{1}{n} \sum_{j=1}^n x_j$$

$$s^2 = \frac{1}{n-1} \sum_{j=1}^n (x_j - \bar{x})^2 = \frac{1}{n-1} \left[\sum_{j=1}^n x_j^2 - \frac{1}{n} \left(\sum_{j=1}^n x_j \right)^2 \right]$$

$$z_j = (x_j - m_0)/k \Rightarrow \begin{cases} \bar{x} = m_0 + k\bar{z} \\ s_x = |k| \cdot s_z \end{cases}$$

8. Punktskattningar

8.1 Maximum-likelihood-metoden

Låt x_i vara en observation på X_i , $i = 1, 2, \dots, n$, där fördelningen för X_i beror på en okänd parameter θ , och antag att X_1, X_2, \dots, X_n är oberoende.

Det värde θ^* som maximerar likelihoodfunktionen

$$L(\theta) = \begin{cases} \prod_{i=1}^n p_{X_i}(x_i; \theta) \\ \prod_{i=1}^n f_{X_i}(x_i; \theta) \end{cases}$$

kallas *maximum-likelihood-skattningen* (ML-skattningen) av θ .

8.2 Minsta-kvadrat-metoden

Låt x_i vara en observation på X_i , $i = 1, 2, \dots, n$, och antag att

$$E(X_i) = m_i(\theta_1, \theta_2, \dots, \theta_k) \text{ och } V(X_i) = \sigma^2,$$

där $\theta_1, \theta_2, \dots, \theta_k$ är okända parametrar och X_1, X_2, \dots, X_n är oberoende.

Minsta-kvadrat-skattningarna (MK-skattningarna) av $\theta_1, \theta_2, \dots, \theta_k$

är de värden $\theta_1^*, \theta_2^*, \dots, \theta_k^*$ som minimerar kvadratsumman

$$Q = Q(\theta_1, \theta_2, \dots, \theta_k) = \sum_{i=1}^n (x_i - m_i(\theta_1, \theta_2, \dots, \theta_k))^2.$$

8.3 Medelfel

Medelfelet till en skattning θ^* är en skattning av standardavvikelsen för θ^* .

9. Några vanliga fördelningar i statistiken

χ^2 -fördelningen

Om X_1, X_2, \dots, X_f är oberoende och $N(0, 1)$ så gäller att

$$\sum_{k=1}^f X_k^2 \text{ är } \chi^2(f)\text{-fördelad.}$$

t -fördelningen

Om X är $N(0, 1)$ och Y är $\chi^2(f)$ samt om X och Y är oberoende så gäller

$$\text{att } \frac{X}{\sqrt{Y/f}} \text{ är } t(f)\text{-fördelad.}$$

10. Stickprovsvariablernas fördelningar vid normalfördelade stickprov

10.1 Låt X_1, \dots, X_n vara oberoende stokastiska variabler som alla är $N(m, \sigma)$.

Då gäller:

- a) \bar{X} är $N\left(m, \frac{\sigma}{\sqrt{n}}\right)$
- b) $(n-1)\frac{s^2}{\sigma^2}$ är $\chi^2(n-1)$
- c) \bar{X} och s^2 är oberoende
- d) $\frac{\bar{X} - m}{s/\sqrt{n}}$ är $t(n-1)$

10.2 Låt X_1, \dots, X_{n_1} vara $N(m_1, \sigma)$ och Y_1, \dots, Y_{n_2} vara $N(m_2, \sigma)$ och samtliga stokastiska variabler antas oberoende. Då gäller:

- a) $\bar{X} - \bar{Y}$ är $N\left(m_1 - m_2, \sigma\sqrt{\frac{1}{n_1} + \frac{1}{n_2}}\right)$
- b) $\frac{(n_1 + n_2 - 2)s^2}{\sigma^2}$ är $\chi^2(n_1 + n_2 - 2)$ där $s^2 = \frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2}$
(s_1^2 och s_2^2 är respektive stickprovsvarians)
- c) $\bar{X} - \bar{Y}$ och s^2 är oberoende
- d) $\frac{\bar{X} - \bar{Y} - (m_1 - m_2)}{s\sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$ är $t(n_1 + n_2 - 2)$

- 10.3** Låt X_1, \dots, X_{n_1} vara $N(m_1, \sigma_1)$ och Y_1, \dots, Y_{n_2} vara $N(m_2, \sigma_2)$ och samtliga stokastiska variabler antas oberoende. Då gäller:

$$\bar{X} - \bar{Y} \text{ är } N\left(m_1 - m_2, \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}\right)$$

11. Konfidensintervall

11.1 λ -metoden

Låt θ^* vara $N(\theta, D)$ där D är känd och θ okänd. Då är $\theta^* \pm D \cdot \lambda_{\alpha/2}$ ett konfidensintervall för θ med konfidensgraden $1 - \alpha$.

11.2 t -metoden

Låt θ^* vara $N(\theta, D)$ där D och θ är okända och D inte beror på θ . Låt d vara en skattning av D sådan att $\frac{\theta^* - \theta}{d}$ är $t(f)$. Då är $\theta^* \pm d \cdot t_{\alpha/2}(f)$ ett konfidensintervall för θ med konfidensgraden $1 - \alpha$.

11.3 Approximativa metoden

Låt θ^* vara approximativt $N(\theta, D)$.

Antag att d är en lämplig skattning av D . Då är

$\theta^* \pm d \cdot \lambda_{\alpha/2}$ ett konfidensintervall för θ med den approximativa konfidensgraden $1 - \alpha$.

11.4 χ^2 -metoden

Låt θ^* vara en skattning av en parameter θ sådan att $f \cdot \left(\frac{\theta^*}{\theta}\right)^2$ är $\chi^2(f)$.

Då är

$$\left(\frac{f \cdot (\theta^*)^2}{\chi^2_{\alpha/2}(f)}, \frac{f \cdot (\theta^*)^2}{\chi^2_{1-\alpha/2}(f)} \right)$$

ett konfidensintervall för θ^2 med konfidensgraden $1 - \alpha$.

12. Linjär regression

12.1 Fördelningar

Låt Y_i vara $N(\alpha + \beta(x_i - \bar{x}), \sigma)$, $i = 1, 2, \dots, n$, och oberoende. Då gäller:

a) $\alpha^* = \bar{Y}$ är $N\left(\alpha, \frac{\sigma}{\sqrt{n}}\right)$

b) $\beta^* = \frac{\sum_{i=1}^n (x_i - \bar{x})(Y_i - \bar{Y})}{\sum_{i=1}^n (x_i - \bar{x})^2}$ är $N\left(\beta, \frac{\sigma}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}}\right)$

c) $\frac{(n-2)s^2}{\sigma^2}$ är $\chi^2(n-2)$ där $s^2 = \frac{1}{n-2} \sum_{i=1}^n (Y_i - \alpha^* - \beta^*(x_i - \bar{x}))^2$

d) α^* , β^* och s^2 är oberoende

12.2 Konfidensintervall

$$I_\alpha : \alpha^* \pm t_{p/2}(n-2) \frac{s}{\sqrt{n}}$$

$$I_\beta : \beta^* \pm t_{p/2}(n-2) \frac{s}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}}$$

$$I_{\alpha+\beta(x_0-\bar{x})} : \alpha^* + \beta^*(x_0 - \bar{x}) \pm t_{p/2}(n-2) s \sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}}$$

12.3 Beräkningsaspekter

$$\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \sum_{i=1}^n (x_i - \bar{x})y_i = \sum_{i=1}^n x_i(y_i - \bar{y}) = \sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}$$

$$\sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n x_i^2 - n \bar{x}^2$$

$$(n-2)s^2 = Q_0 = \sum_{i=1}^n (y_i - \bar{y})^2 - \beta^{*2} \sum_{i=1}^n (x_i - \bar{x})^2$$

13. Hypotesprövning

13.1 Definitioner

Signifikansnivån (felrisken) α är (det maximala värdet av) $P(\text{förkasta } H_0)$ då hypotesen H_0 är sann.

Styrkefunktionen $h(\theta) = P(\text{förkasta } H_0)$ då θ är rätt parametervärde.

13.2 Konfidensmetoden

Förkasta $H_0 : \theta = \theta_0$ om θ_0 ej faller inom ett lämpligt valt konfidensintervall med motsvarande konfidensgrad.

13.3 χ^2 -test

Man gör n oberoende upprepningar av ett försök som ger något av resultaten A_1, A_2, \dots, A_r med respektive sannolikheter p_1, p_2, \dots, p_r . Låt för $j = 1, 2, \dots, r$ den stokastiska variabeln X_j beteckna antalet försök som ger resultatet A_j . Då blir

$$Q = \sum_{j=1}^r \frac{(X_j - np_j)^2}{np_j} \text{ approximativt } \chi^2(r-1)\text{-fördelad}$$

då p_1, p_2, \dots, p_r är kända och $np_j \geq 5$, $j = 1, 2, \dots, r$.

Om vi skattar k parametrar ur data för att skatta p_1, p_2, \dots, p_r med $p_1^*, p_2^*, \dots, p_r^*$ så är

$$Q' = \sum_{j=1}^r \frac{(X_j - np_j^*)^2}{np_j^*} \text{ approximativt } \chi^2(r-k-1)\text{-fördelad.}$$

Homogenitetstest: Man vill testa om sannolikheterna för resultaten A_1, A_2, \dots, A_r är desamma i s försöksserier. Inför beteckningar enligt nedanstående tabell:

Serie	Antal observationer av					Antal försök
	A_1	A_2	A_3	\dots	A_r	
1	x_{11}	x_{12}	x_{13}	\dots	x_{1r}	n_1
2	x_{21}	x_{22}	x_{23}	\dots	x_{2r}	n_2
\vdots	\vdots					\vdots
s	x_{s1}	x_{s2}	x_{s3}	\dots	x_{sr}	n_s

Bilda $Q = \sum_{i=1}^s \sum_{j=1}^r \frac{(x_{ij} - n_i p_j^*)^2}{n_i p_j^*}$

där $p_j^* = \frac{1}{N} \sum_{i=1}^s x_{ij}$, $j = 1, 2, \dots, r$, $N = \sum_{i=1}^s n_i$

Q är approximativt $\chi^2((r-1)(s-1))$ -fördelad.

Beräkningsaspekt: $Q = \sum_{j=1}^r \frac{x_j^2}{np_j} - n$, $Q' = \sum_{j=1}^r \frac{x_j^2}{np_j^*} - n$