

Matematisk statistik

KTH

# **Formel- och tabellsamling i matematisk statistik**

## 1. Kombinatorik

$\binom{n}{k} = \frac{n!}{k!(n-k)!}$ . Tolkning:  $\binom{n}{k}$  = antalet delmängder av storlek  $k$  ur en mängd med  $n$  element.

## 2. Stokastiska variabler

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

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

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

## 3. 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 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  $p_X(k) = \frac{\binom{Np}{k} \binom{N(1-p)}{n-k}}{\binom{N}{n}}$ ,  $0 \leq k \leq Np$ ,

$0 \leq n - k \leq N(1-p)$ , där  $N$ ,  $Np$  och  $n$  är positiva heltal samt  $N \geq 2$ ,

$$n < N, \quad 0 < p < 1. \quad E(X) = np, \quad V(X) = \frac{N-n}{N-1} \cdot np(1-p)$$

### Poissonfördelningen

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

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

## 4. Kontinuerliga fördelningar

### Likformig fördelning

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

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

### Exponentialfördelningen

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

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

### Normalfördelningen

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

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

$$X \text{ är } N(\mu, \sigma^2) \text{ om och endast om } \frac{X - \mu}{\sigma} \text{ är } N(0, 1).$$

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

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

## 5. Centrala gränsvärdessatsen

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

## 6. Approximation

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

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

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

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

## 7. Tjebysjovs olikhet

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

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

## 8. Statistiskt material

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

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

## 9. Punktskattningar

### 9.1 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  $\theta$ . Det värde  $\theta_{\text{obs}}^*$  som maximerar  $L$ -funktionen

$$L(\theta) = \begin{cases} p_{X_1, \dots, X_n}(x_1, \dots, x_n; \theta) & (\text{om oberoende}) = p_{X_1}(x_1; \theta) \cdots p_{X_n}(x_n; \theta) \\ f_{X_1, \dots, X_n}(x_1, \dots, x_n; \theta) & (\text{om oberoende}) = f_{X_1}(x_1; \theta) \cdots f_{X_n}(x_n; \theta) \end{cases}$$

kallas *maximum-likelihood-skattningen (ML-skattningen)* av  $\theta$ .

### 9.2 Minsta-kvadrat-metoden

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

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

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  $(\theta_1)_{\text{obs}}^*, (\theta_2)_{\text{obs}}^*, \dots, (\theta_k)_{\text{obs}}^*$  som minimerar kvadratsumman

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

### 9.3 Medelfel

En skattning av  $D(\theta^*)$  kallas *medelfelet* för  $\theta^*$  och betecknas  $d(\theta^*)$ .

### 9.4 Felfortplantning

Med beteckningar och förutsättningar enligt läroboken gäller

a)  $E(g(\theta^*)) \approx g(\theta_{\text{obs}}^*)$

$$D(g(\theta^*)) \approx |g'(\theta_{\text{obs}}^*)| \cdot D(\theta^*)$$

b)  $E(g(\theta_1^*, \dots, \theta_n^*)) \approx g((\theta_1)_{\text{obs}}^*, \dots, (\theta_n)_{\text{obs}}^*)$

$$V(g(\theta_1^*, \dots, \theta_n^*)) \approx \sum_{i=1}^n \sum_{j=1}^n C(\theta_i^*, \theta_j^*) \cdot \left[ \frac{\partial g}{\partial x_i} \cdot \frac{\partial g}{\partial x_j} \right]_{x_k=(\theta_k)_{\text{obs}}^*, k=1, \dots, n}$$

## 10. Några vanliga fördelningar i statistiken

### $\chi^2$ -fördelningen

Om  $X_1, X_2, \dots, X_f$  är oberoende och  $N(0, 1)$  så gäller att  
 $\sum_{k=1}^f X_k^2$  är  $\chi^2(f)$ -fördelad.

### $t$ -fördelningen

Om  $X$  är  $N(0, 1)$  och  $Y$  är  $\chi^2(f)$  samt om  $X$  och  $Y$  är oberoende så gäller  
att  $\frac{X}{\sqrt{Y/f}}$  är  $t(f)$ -fördelad.

## 11. Stickprovsvariablernas fördelningar vid normalfördelade stickprov

**11.1** Låt  $X_1, \dots, X_n$  vara oberoende stokastiska variabler som alla är  $N(\mu, \sigma)$ .

Då gäller:

a)  $\bar{X}$  är  $N\left(\mu, \frac{\sigma}{\sqrt{n}}\right)$

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

c)  $\bar{X}$  och  $S^2$  är oberoende

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

**11.2** Låt  $X_1, \dots, X_{n_1}$  vara  $N(\mu_1, \sigma)$  och  $Y_1, \dots, Y_{n_2}$  vara  $N(\mu_2, \sigma)$  och samtliga stokastiska variabler antas oberoende. Då gäller:

a)  $\bar{X} - \bar{Y}$  är  $N\left(\mu_1 - \mu_2, \sigma\sqrt{\frac{1}{n_1} + \frac{1}{n_2}}\right)$

b)  $\frac{(n_1 + n_2 - 2)S^2}{\sigma^2}$  är  $\chi^2(n_1 + n_2 - 2)$  där  $S^2 = \frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{n_1 + n_2 - 2}$ ,

$$S_1^2 = \frac{1}{n_1 - 1} \sum_{i=1}^{n_1} (X_i - \bar{X})^2 \text{ och } S_2^2 = \frac{1}{n_2 - 1} \sum_{i=1}^{n_2} (Y_i - \bar{Y})^2$$

c)  $\bar{X} - \bar{Y}$  och  $S^2$  är oberoende

d)  $\frac{\bar{X} - \bar{Y} - (\mu_1 - \mu_2)}{S\sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$  är  $t(n_1 + n_2 - 2)$

**11.3** Låt  $X_1, \dots, X_{n_1}$  vara  $N(\mu_1, \sigma_1)$  och  $Y_1, \dots, Y_{n_2}$  vara  $N(\mu_2, \sigma_2)$  och samtliga stokastiska variabler antas oberoende. Då gäller:

$$\bar{X} - \bar{Y} \text{ är } N\left(\mu_1 - \mu_2, \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}\right)$$

## 12. Konfidensintervall

### 12.1 $\lambda$ -metoden

Låt  $\theta^*$  vara  $N(\theta, D)$  där  $D$  är känd och  $\theta$  okänd. Då är

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

ett konfidensintervall för  $\theta$  med konfidensgraden  $1 - \alpha$ .

## 12.2 *t*-metoden

Låt  $\theta^*$  vara  $N(\theta, D)$  där  $D$  och  $\theta$  är okända och  $D$  inte beror på  $\theta$ .

Låt  $D_{\text{obs}}^*$  vara en punktskattning av  $D$  sådan att  $\frac{\theta^* - \theta}{D^*}$  är  $t(f)$ . Då är  $\theta_{\text{obs}}^* \pm D_{\text{obs}}^* \cdot t_{\alpha/2}(f)$  ett konfidensintervall för  $\theta$  med konfidensgraden  $1 - \alpha$ .

## 12.3 Approximativa metoden

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

Antag att  $D_{\text{obs}}^*$  är en lämplig punktskattning av  $D$ . Då är  $\theta_{\text{obs}}^* \pm D_{\text{obs}}^* \cdot \lambda_{\alpha/2}$  ett konfidensintervall för  $\theta$  med den *approximativa* konfidensgraden  $1 - \alpha$ .

## 12.4 Metod baserad på $\chi^2$ -fördelning

Låt  $\theta_{\text{obs}}^*$  vara en punktskattning av en parameter  $\theta$  sådan att

$f \cdot \left(\frac{\theta^*}{\theta}\right)^2$  är  $\chi^2(f)$ . Då är

$$\left( \theta_{\text{obs}}^* \sqrt{\frac{f}{\chi_{\alpha/2}^2(f)}}, \theta_{\text{obs}}^* \sqrt{\frac{f}{\chi_{1-\alpha/2}^2(f)}} \right)$$

ett konfidensintervall för  $\theta$  med konfidensgraden  $1 - \alpha$ .

# 13. Linjär regression

## 13.1 Fördelningar

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

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

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

c)  $\alpha^* + \beta^* x_0$  är  $N\left(\alpha + \beta x_0, \sigma \sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}}\right)$

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

e)  $S^2$  är oberoende av  $\alpha^*$  och  $\beta^*$

### 13.2 Konfidensintervall

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

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

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

### 13.3 Beräkningsaspekter

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

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

$$S_{yy} = \sum_{i=1}^n (y_i - \bar{y})^2$$

$$(n-2)s^2 = S_{yy} - (\beta_{\text{obs}}^*)^2 S_{xx} = S_{yy} - \beta_{\text{obs}}^* \cdot S_{xy} = \min_{\alpha, \beta} \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2$$

## 14. Hypotesprövning

### 14.1 Definitioner

Signifikansnivå (felrisken)  $\alpha$  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  $\theta$  är rätt parametervärde.

### 14.2 Konfidensmetoden

Förkasta  $H_0: \theta = \theta_0$  på nivå  $\alpha$  om  $\theta_0$  ej faller inom ett lämpligt valt konfidensintervall med konfidensgraden  $1 - \alpha$ .

### 14.3 $\chi^2$ -test

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

Test av given fördelning: Vi vill testa  $H_0 : P(A_1) = p_1, P(A_2) = p_2, \dots,$

$P(A_r) = p_r$  för givna sannolikheter  $p_1, p_2, \dots, p_r$ . Då blir

$$Q = \sum_{j=1}^r \frac{(x_j - np_j)^2}{np_j} \text{ ett utfall av en approximativt } \chi^2(r-1)\text{-fördelad}$$

stokastisk variabel om  $H_0$  är sann och  $np_j \geq 5$ ,  $j = 1, 2, \dots, r$ .

Om vi skattar  $k$  parametrar ur data,  $\theta = (\theta_1, \dots, \theta_k)$ , för att skatta

$p_1, p_2, \dots, p_r$  med  $p_1(\theta_{\text{obs}}^*), p_2(\theta_{\text{obs}}^*), \dots, p_r(\theta_{\text{obs}}^*)$  så är

$$Q' = \sum_{j=1}^r \frac{(x_j - np_j(\theta_{\text{obs}}^*))^2}{np_j(\theta_{\text{obs}}^*)} \text{ ett utfall av en approximativt}$$

$\chi^2(r-k-1)$ -fördelad stokastisk variabel.

$$\text{Beräkningsaspekt: } Q = \sum_{j=1}^r \frac{x_j^2}{np_j} - n, \quad Q' = \sum_{j=1}^r \frac{x_j^2}{np_j(\theta_{\text{obs}}^*)} - n$$

*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	$x_{21}$	$x_{22}$	$x_{23}$	$\dots$	$x_{2r}$	$n_2$
$\vdots$	$\vdots$					$\vdots$
$s$	$x_{s1}$	$x_{s2}$	$x_{s3}$	$\dots$	$x_{sr}$	$n_s$
Kolonnsumma	$m_1$	$m_2$	$m_3$	$\dots$	$m_r$	$N$

$$\text{Bilda } Q = \sum_{i=1}^s \sum_{j=1}^r \frac{\left(x_{ij} - \frac{n_i m_j}{N}\right)^2}{\frac{n_i m_j}{N}}.$$

$Q$  är ett utfall av en approximativt  $\chi^2((r-1)(s-1))$ -fördelad stokastisk variabel.

*Kontingenstabell (test av oberoende mellan rader och kolonner):*

Samma teststyrka och fördelning som ovan.