

# Formelblad – Sannolikhetssteori 1

**Bayes formel:** Låt  $A$  och  $D$  vara två händelser. Då gäller

$$P(A|D) = \frac{P(D|A)P(A)}{P(D)}.$$

**Chebyshevs olikhet:** Låt  $X$  vara en stokastisk variabel med väntevärde  $\mu$  och varians  $\sigma^2$ . Då gäller för alla  $c > 0$  att

$$P(|X - \mu| \geq c) \leq \frac{\sigma^2}{c^2}.$$

**Geometrisk serie:** För en geometrisk serie gäller då  $|x| < 1$

$$\sum_{i=0}^{\infty} ax^i = \frac{a}{1-x},$$

och delsumman  $S_n$  (summan av de  $n$  första termerna) gäller då  $x \neq 1$

$$S_n = a \frac{1-x^{n+1}}{1-x}.$$

## Diskreta fördelningar

**Binomialfördelning:**  $X \sim Bin(n, p)$

- frekvensfunktionen  $P(X = x) = \binom{n}{x} p^x (1-p)^{n-x}$ ,  $x = 0, 1, \dots, n$
- väntevärdet  $np$
- variansen  $np(1-p)$
- momentgenererande funktionen  $M_X(t) = (pe^t + 1 - p)^n$

**Poissonfördelning:**  $X \sim Pois(\lambda)$

- frekvensfunktionen  $P(X = x) = e^{-\lambda} \cdot \frac{\lambda^x}{x!}$ ,  $x = 0, 1, 2, \dots$
- väntevärdet  $\lambda$
- variansen  $\lambda$
- momentgenererande funktionen  $M_X(t) = \exp(\lambda(e^t - 1))$

**Geometrisk fördelning:**  $X \sim Geom(p)$

- frekvensfunktionen  $P(X = x) = (1-p)^{x-1} p$ ,  $x = 1, 2, \dots$
- väntevärdet  $\frac{1}{p}$
- variansen  $\frac{1-p}{p^2}$

**Negativ binomialfördelning:**  $X \sim NegBin(r, p)$

- frekvensfunktionen  $P(X = x) = \binom{x-1}{r-1} p^r (1-p)^{x-r}$ ,  $x = r, r+1, \dots$
- väntevärdet  $\frac{r}{p}$
- variansen  $\frac{r(1-p)}{p^2}$

**Hypergeometrisk fördelning:**  $X \sim HypGeom(n, N, m)$

- frekvensfunktionen  $P(X = x) = \frac{\binom{m}{x} \binom{N-m}{n-x}}{\binom{N}{n}}, \quad x = 0, 1, \dots, n$
- väntevärdet  $\frac{nm}{N}$
- variansen  $\frac{nm}{N} \left( \frac{(n-1)(m-1)}{N-1} + 1 - \frac{nm}{N} \right)$

## Kontinuerliga fördelningar

**Likformig fördelning:**  $X \sim Lik(a, b)$

- täthetsfunktionen  $f(x) = \frac{1}{b-a}, \quad a < x < b$
- väntevärdet  $\frac{1}{2}(a+b)$
- variansen  $\frac{1}{12}(b-a)^2$
- momentgenererande funktionen  $M_X(t) = \frac{e^{tb} - e^{ta}}{t(b-a)}$

**Normalfördelning:**  $X \sim N(\mu, \sigma^2)$

- täthetsfunktionen  $f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right), \quad -\infty < x < \infty$
- väntevärdet  $\mu$
- variansen  $\sigma^2$
- momentgenererande funktionen  $M_X(t) = \exp(\mu t + \sigma^2 t^2 / 2)$

**Standardiserad normalfördelning:**  $Z \sim N(0, 1)$

- täthetsfunktionen  $f(z) = \frac{1}{\sqrt{2\pi}} e^{-z^2/2}, \quad -\infty < z < \infty$
- momentgenererande funktionen  $M_Z(t) = \exp(t^2/2)$

**Exponentialfördelning:**  $X \sim Exp(\lambda)$

- täthetsfunktionen  $f(x) = \lambda e^{-\lambda x}, \quad x \geq 0$
- väntevärdet  $\frac{1}{\lambda}$
- variansen  $\frac{1}{\lambda^2}$
- momentgenererande funktionen  $M_X(t) = \frac{\lambda}{\lambda-t}$

**Gammafördelning:**  $X \sim Gamma(s, \lambda)$

- täthetsfunktionen  $f(x) = \frac{\lambda e^{-\lambda x} (\lambda x)^{s-1}}{\Gamma(s)}, \quad x \geq 0$ , där  $\Gamma(s) = \int_0^\infty e^{-y} y^{s-1} dy$
- väntevärdet  $\frac{s}{\lambda}$
- variansen  $\frac{s}{\lambda^2}$
- momentgenererande funktionen  $M_X(t) = \left(\frac{\lambda}{\lambda-t}\right)^s$

**Student t-fördelning:**  $T \sim t_r, \quad r = 1, 2, \dots$

- täthetsfunktionen  $f(t) = \frac{\Gamma((r+1)/2)}{\sqrt{r\pi}\Gamma(r/2)} \left(1 + \frac{t^2}{r}\right)^{-(r+1)/2}, \quad t \in \mathbb{R}$ , där  $\Gamma(s) = \int_0^\infty e^{-y} y^{s-1} dy$
- väntevärdet 0
- variansen  $\frac{r}{r-2}$ , för  $r \geq 3$

**$\chi^2$ -fördelning:**  $X \sim \chi_r^2$ ,  $r = 1, 2, \dots$

– täthetsfunktionen  $f(x) = \frac{1}{r^r 2^r \Gamma(r/2)} x^{r/2-1} e^{-x/2}$ ,  $x \in \mathbb{R}$ , där  $\Gamma(s) = \int_0^\infty e^{-y} y^{s-1} dy$

– väntevärdet  $r$

– variansen  $2r$

**Bivariat normalfördelning:** En två-dimensionell stokastisk variabel  $(X, Y)$  har en bivariat normalfördelning med parametrar  $\mu_1, \mu_2, \sigma_1^2, \sigma_2^2$  och  $\rho$ , om dess täthetsfunktion är

$$f(x, y) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \cdot \exp\left(-\frac{1}{2(1-\rho^2)}\left(\left(\frac{x-\mu_1}{\sigma_1}\right)^2 - 2\rho\left(\frac{x-\mu_1}{\sigma_1}\right)\left(\frac{y-\mu_2}{\sigma_2}\right) + \left(\frac{y-\mu_2}{\sigma_2}\right)^2\right)\right).$$

Den betingade fördelningen av  $Y$  givet  $X = x$  är normalfördelning med väntevärde  $\mu_2 + \rho\frac{\sigma_2}{\sigma_1}(x - \mu_1)$  och varians  $\sigma_2^2(1 - \rho^2)$ . Om  $(X, Y)$  har en bivariat normalfördelning med parametrar  $\mu_1, \mu_2, \sigma_1^2, \sigma_2^2$  och  $\rho$ , då har  $\left(\frac{X-\mu_1}{\sigma_1}, \frac{Y-\mu_2}{\sigma_2}\right)$  bivariat normalfördelning med parametrar  $0, 0, 1, 1$  och  $\rho$ .

## Exempel om hur olika fördelningar kan tillämpas

- **Binomial:** Antal succéer i  $n$  oberoende försök, där succésannolikheten är  $p$ , är binomialfördelat.
- **Poisson:** Kan användas som fördelning för antal punkter i en stokastisk punktprocess (under några enkla antaganden). Approximerar binomialfördelningen, när  $n$  är stor och  $p$  liten,  $\lambda = np$ .
- **Geometrisk:** Antal försök, som behövs tills en händelse med sannolikhet  $p$  inträffar, har geometrisk fördelning.
- **Negativ binomial:** Antal försök, som behövs tills en händelse med sannolikhet  $p$  inträffar för  $r$ -te gången, har negativ binomialfördelning.
- **Hypergeometrisk:** Man använder fördelningen om man drar utan återläggning från en ändlig population som har två olika slags individer.
- **Likformig:** Används som fördelning för väntetider och avrundning av mättningsfel.
- **Normal:** Under generella antaganden är en summa av ett stort antal stokastiska variabler approximativt normalfördelat (centrala gränsvärdessatsen).
- **Standardiserad normal:** Om  $X \sim N(\mu, \sigma)$ , då har  $\frac{X-\mu}{\sigma}$  standardiserad normalfördelning.
- **Exponential:** Fördelning för livslängd (utan åldrande).
- **Gamma:** Fördelning för summan av  $n$  oberoende stokastiska variabler, som är exponentialfördelade med parameter  $\lambda$ .

## Summer av oberoende stokastiska variabler

- $X_1 \sim Bin(n_1, p)$  och  $X_2 \sim Bin(n_2, p)$ :  $X_1 + X_2 \sim Bin(n_1 + n_2, p)$
- $X_1 \sim Pois(\lambda_1)$  och  $X_2 \sim Pois(\lambda_2)$ :  $X_1 + X_2 \sim Pois(\lambda_1 + \lambda_2)$
- $X_1 \sim Exp(\lambda)$  och  $X_2 \sim Exp(\lambda)$ :  $X_1 + X_2 \sim Gamma(2, \lambda)$

- $X_1 \sim \text{Gamma}(n_1, \lambda)$  och  $X_2 \sim \text{Gamma}(n_2, \lambda)$ :  
 $X_1 + X_2 \sim \text{Gamma}(n_1 + n_2, \lambda)$
- $X_1 \sim N(\mu_1, \sigma_1^2)$  och  $X_2 \sim N(\mu_2, \sigma_2^2)$ :  $X_1 + X_2 \sim N(\mu_1 + \mu_2, \sigma_1^2 + \sigma_2^2)$
- $X_1, X_2, \dots, X_n$  är  $N(0, 1)$ :  $\sum_{k=1}^n X_k^2 \sim \chi_n^2$
- $X_1 \sim \chi_n^2$  och  $X_2 \sim \chi_m^2$ :  $X_1 + X_2 \sim \chi_{n+m}^2$
- $X_1 \sim N(0, 1)$  och  $X_2 \sim \chi_n^2$ :  $\frac{X_1}{\sqrt{X_2/n}} \sim t_n$

## Statistikor

- **Ett stickprov:** Låt  $X_1, X_2, \dots, X_n$  vara oberoende normalfördelade stokastiska variabler med väntevärde  $\mu$  och varians  $\sigma^2$ .

- *Stickprovsväntevärde:*  $\bar{X} = \frac{1}{n} \sum_{k=1}^n X_k$  är en väntevärdesriktig skattare för  $\mu$ , och

$$\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right).$$

- *Stickprovsvarians:*  $s^2 = \frac{1}{n-1} \sum_{k=1}^n (X_k - \bar{X})^2 = \frac{1}{n-1} (\sum_{k=1}^n X_k^2 - n\bar{X}^2)$  är en väntevärdesriktig skattare för  $\sigma^2$ , och

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

- *Ett stickprov t-statistika:*

$$T = \frac{\bar{X} - \mu}{s/\sqrt{n}} \sim t_{n-1}$$

- **Två stickprov, lika varians:** Låt  $X_1, X_2, \dots, X_n$  och  $Y_1, Y_2, \dots, Y_m$  vara två oberoende stickprov från en  $N(\mu_1, \sigma^2)$ - respektive  $N(\mu_2, \sigma^2)$ -fördelning. Låt  $s_1^2$  respektive  $s_2^2$  beteckna stickprovsvariansen för vardera stickprov.

- *Sammanvägd stickprovsvarians:*  $s_p^2 = \frac{(n-1)s_1^2 + (m-1)s_2^2}{n+m-2}$  är en väntevärdesriktig skattare för  $\sigma^2$ , och

$$\frac{(n+m-2)s_p^2}{\sigma^2} \sim \chi_{n+m-2}^2.$$

- *Två stickprov t-statistika:*

$$T = \frac{\bar{X} - \bar{Y} - (\mu_1 - \mu_2)}{s_p \sqrt{\frac{1}{n} + \frac{1}{m}}} \sim t_{n+m-2}$$

- **Två stickprov, parvis observationer:** Låt  $(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)$  vara ett stickprov av parvis observationer sådana att  $(X_k, Y_k)$  är bivariat normalfördelade med parametrar  $\mu_k, \mu_k + \Delta, \sigma_1^2, \sigma_2^2$  och  $\rho$ . Sätt  $D_k = X_k - Y_k$  och låt  $s_D^2$  vara stickprovsvariansen för  $D_1, D_2, \dots, D_n$ . Då är

$$D_k \sim N(\Delta, \sigma_1^2 + \sigma_2^2 - 2\rho\sigma_1\sigma_2).$$

- *t-statistika:*

$$T = \frac{\bar{D} - (\mu_1 - \mu_2)}{s_D \sqrt{n}} \sim t_{n-1}$$

– *Stickprovskorrelationskoefficient:*

$$R = \frac{\sum_{k=1}^n (X_k - \bar{X})(Y_k - \bar{Y})}{\sqrt{\sum_{k=1}^n (X_k - \bar{X})^2 \sum_{k=1}^n (Y_k - \bar{Y})^2}}$$

$$= \frac{\sum_{k=1}^n X_k Y_k - n\bar{X}\bar{Y}}{\sqrt{(\sum_{k=1}^n X_k^2 - n\bar{X}^2) (\sum_{k=1}^n Y_k^2 - n\bar{Y}^2)}}$$

– Om  $\rho = 0$ , så är  $T = \frac{(n-2)R}{\sqrt{1-R^2}} \sim t_{n-2}$ .

• **Okända sannolikheter/populationsandelar:** Låt  $X \sim \text{Bin}(n, p)$  och  $Y \sim \text{Bin}(m, q)$  vara oberoende.

–  $\hat{p} = \frac{X}{n}$  och  $\hat{q} = \frac{Y}{m}$  är väntevärdesriktiga skattare för  $p$  respektive  $q$ .

– För stora  $n$  gäller

$$\frac{\hat{p} - p}{\sqrt{p(1-p)/n}} \stackrel{d}{\approx} N(0, 1),$$

enligt centrala gränsvärdesatsen. Eftersom  $\hat{p} \rightarrow p$  i sannolikhet då  $n \rightarrow \infty$ , så gäller vidare att

$$\frac{\hat{p} - p}{\sqrt{\hat{p}(1-\hat{p})/n}} \stackrel{d}{\approx} N(0, 1),$$

för stora  $n$ .

– För  $\min(n, m)$  stort gäller

$$\hat{p} - \hat{q} \stackrel{d}{\approx} N\left(p - q, \frac{p(1-p)}{n} + \frac{q(1-q)}{m}\right),$$

enligt centrala gränsvärdesatsen. Eftersom  $\hat{p} - \hat{q} \rightarrow p - q$  i sannolikhet då  $\min(n, m) \rightarrow \infty$ , så gäller vidare att

$$\frac{\hat{p} - \hat{q} - (p - q)}{\sqrt{\frac{\hat{p}(1-\hat{p})}{n} + \frac{\hat{q}(1-\hat{q})}{m}}} \stackrel{d}{\approx} N(0, 1),$$

då  $\min(n, m)$  är stort.

• **Jämförelse av sannolikheter/populationsandelar:** Antag att utfallet av ett försök kan hamna i  $r$  olika kategorier, vardera med sannolikhet  $p_1, p_2, \dots, p_r$ . Låt  $X_k$  beteckna antalet utfall i kategori  $k$  vid  $n$  oberoende försök.

–  $\hat{p}_k = \frac{X_k}{n}$  är en väntevärdesriktig skattare för  $p_k$ , för  $k = 1, 2, \dots, r$ .

– *Parvis jämförelse av okända sannolikheter/populationsandelar:* För stora  $n$  gäller

$$\hat{p}_k - \hat{p}_l \stackrel{d}{\approx} N\left(p_k - p_l, \frac{p_k + p_l - (p_k - p_l)^2}{n}\right),$$

enligt centrala gränsvärdesatsen.

– *Jämförelse av uppmätta och teoretiska frekvenser:*

$$\chi^2 = \sum_{k=1}^r \frac{(X_k - np_k)^2}{np_k} \stackrel{d}{\approx} \chi_{r-1}^2$$

Approximationen är ej pålitlig om  $np_k < 5$  för något  $k = 1, 2, \dots, r$ .

- **Icke-parametriska metoder:** Låt  $X_1, X_2, \dots, X_n$  vara oberoende stokastiska variabler från en kontinuerlig fördelning med väntevärde  $\mu$  och median  $m$ . Låt  $R_k$  vara rangen av  $X_k$  då  $|X_k - \mu|$  ordnas i stigande ordning. Låt  $I_k = I_{\{X_k > \mu\}}$  indikera om  $X_k > \mu$ .

– Teckenstatistika:  $N_+ = \#\{k : X_k > m\} \sim \text{Bin}(n, \frac{1}{2})$ .

– Wilcoxon teckenrang-statistika:  $W = \sum_{k=1}^n R_k I_k$

– Om stickprovsfördelningen är symmetrisk, så är  $m = \mu$  och  $W$  symmetriskt fördelat över  $0, 1, \dots, \frac{n(n+1)}{2}$ .

– Om stickprovsfördelningen är symmetrisk, så gäller för stora  $n$  att

$$W \stackrel{d}{\approx} N\left(\frac{n(n+1)}{4}, \frac{n(n+1)(2n+1)}{24}\right).$$

## Linjär regression

Låt  $(x_1, Y_1), (x_2, Y_2), \dots, (x_n, Y_n)$  vara oberoende observationer sådana att  $Y_k \sim N(\alpha + \beta x_k, \sigma^2)$  för några konstanter  $\alpha, \beta \in \mathbb{R}$ . Låt

$$\begin{aligned} S_x &= \sum_{k=1}^n x_k, & S_Y &= \sum_{k=1}^n Y_k, \\ S_{xx} &= \sum_{k=1}^n x_k^2, & S_{xY} &= \sum_{k=1}^n x_k Y_k. \end{aligned}$$

- **Skattning av koeficienter:** Maximum Likelihood-skattarna för  $\beta$  respektive  $\alpha$  ges av

$$\begin{aligned} \hat{\beta} &= \frac{\sum_{k=1}^n (x_k - \bar{x})(Y_k - \bar{Y})}{\sum_{k=1}^n (x_k - \bar{x})^2} = \frac{nS_{xY} - S_x S_Y}{nS_{xx} - S_x^2}, \\ \hat{\alpha} &= \bar{Y} - \hat{\beta} \bar{x}. \end{aligned}$$

–  $\hat{\alpha} \sim N(\alpha, \text{Var}(\hat{\alpha}))$  och  $\hat{\beta} \sim N(\beta, \text{Var}(\hat{\beta}))$ , där

$$\begin{aligned} \text{Var}(\hat{\alpha}) &= \frac{\sigma^2 \sum_{k=1}^n x_k^2}{n \sum_{k=1}^n (x_k - \bar{x})^2} = \frac{\sigma^2 S_{xx}}{nS_{xx} - S_x^2}, \\ \text{Var}(\hat{\beta}) &= \frac{\sigma^2}{\sum_{k=1}^n (x_k - \bar{x})^2} = \frac{\sigma^2}{S_{xx} - S_x^2/n}. \end{aligned}$$

–  $s^2 = \frac{1}{n-2} \sum_{k=1}^n (Y_k - \hat{\alpha} - \hat{\beta} x_k)^2$  är väntevärdesriktig skattare för  $\sigma^2$ , och

$$\frac{(n-2)s^2}{\sigma^2} \sim \chi_{n-2}^2.$$

–  $T_\alpha = \frac{\hat{\alpha} - \alpha}{s} \sqrt{n - \frac{S_x^2}{S_{xx}}} \sim t_{n-2}$  och  $T_\beta = \frac{\hat{\beta} - \beta}{s} \sqrt{S_{xx} - \frac{S_x^2}{n}} \sim t_{n-2}$ .

- **Prediktion av ny observation:** Låt  $(x, Y)$  vara en observation sådan att  $Y \sim N(\alpha + \beta x, \sigma^2)$ . Givet  $x$ , så är  $\hat{\alpha} + \hat{\beta} x$  är en väntevärdesriktig skattare för  $Y$ . Om  $(x, Y)$  är oberoende av tidigare observationer så är

$$T = \frac{Y - (\hat{\alpha} + \hat{\beta} x)}{s \sqrt{1 + \frac{1}{n} + \frac{n(x - \bar{x})^2}{nS_{xx} - S_x^2}}} \sim t_{n-2}.$$