

Markovkedjor

- tillståndsrum $S = \{s_1, \dots, s_r\}$ och övergångsmatris $P = (p_{ij})_{i,j=1,\dots,r}$ där
 $p_{ij} = P(X_{n+1} = s_j | X_n = s_i)$ för godtyckligt $n \in \mathbb{N}_0$, $\sum_{j=1}^r p_{ij} = 1$ (P radstokastisk)
- flerstegs övergångsslh. $P(X_n = s_j | X_0 = s_i) = (P^n)_{ij}$ (element (i,j) i matrispotensen P^n)
- multiplikation från höger! $u^{(n)} := (P(X_n = s_1), P(X_n = s_2), \dots, P(X_n = s_r)) \in [0,1]^r$
 $\rightarrow u^{(n)} = u^{(0)} \cdot P^n$
- MK är irreducibel om $(P^n)_{ij} > 0$ för godtyckliga i,j och något n
 MK är **reguljär** om $(P^n)_{ij} > 0$ för något fast $n \in \mathbb{N}_0$ och alla i,j
- För en reguljär MK gäller $P^n \rightarrow \Pi = \begin{pmatrix} - & \pi & - \\ - & \pi & - \end{pmatrix}$ där $\pi = (\pi_1, \dots, \pi_r)$ kallas gränsfördelning.
- tillstånd s_j absorberande om $p_{jj} = 1$, transient om det har pos. slh. att aldrig återvända
- För en **absorberande** MK väljer vi **kanonisk form** $P = \begin{matrix} \text{trans.} & \text{abs.} \\ \begin{pmatrix} Q & R \\ 0 & I_r \end{pmatrix} \end{matrix}$
 $\Rightarrow P^n \rightarrow \begin{pmatrix} 0 & NR \\ 0 & I_r \end{pmatrix}$ där $N = (I_t - Q)^{-1}$ är den **fundamentala matrisen**
- n_{ij} = förväntade antalet besök i s_j med start i s_i (där s_i, s_j är transienta)
- $d = N \cdot \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix}$ anger: d_j = tiden till absorption efter start i tillstånd s_j (transient)

genererande funktioner

$g(x) = \sum_{n=0}^{\infty} a_n x^n$ till en given talföljd $(a_n)_{n \in \mathbb{N}_0}$

viktiga g.f. $g(x) = \sum_{n=0}^{\infty} (cx)^n = \frac{1}{1-cx}$ [$|cx| < 1$] geometrisk

$g(x) = \sum_{k=0}^{\infty} \binom{n}{k} x^k = (1+x)^n$ binomial

$g(x) = \sum_{n=0}^{\infty} \binom{n+k}{k} x^n = \frac{1}{(1-x)^{k+1}}$ [$|x| < 1$]

- kan användas till att räkna antalet heltalslösningar till $y_1 + y_2 + \dots + y_k = n$ med givna restriktioner [koeff. framför x^n i $g_1(x) \dots g_k(x)$ där $g_i(x) = \sum_{n \text{ tillåtet värde}} x^n$]
- kan användas till att lösa rekursioner (ibland tillsammans med partialbräks uppdelning) [gångra rekursionen med x^n , summera över tillåtna n , lösa ut $g(x)$, skriva om till potensserie]

Exponentiella gen. fkt.

$g(x) = \sum_{n=0}^{\infty} a_n \frac{x^n}{n!}$ till en given talföljd $(a_n)_{n \in \mathbb{N}_0}$


- kan användas till att räkna antalet strängar med "bokstäver" ur ett givet alfabet med restriktioner [strategi: summera som ovan fast nu med exp. gen. fkt.]
- vanliga: $e^{cx} = \sum_{n=0}^{\infty} \frac{(cx)^n}{n!}$, $\cosh(x) = \frac{e^x + e^{-x}}{2} = \sum_{n=0}^{\infty} \frac{x^{2n}}{(2n)!}$, $\sinh(x) = \frac{e^x - e^{-x}}{2} = \sum_{n=0}^{\infty} \frac{x^{2n+1}}{(2n+1)!}$

Statistik

Beskrivande S.

histogram (variationsbredd, rel. frekvenser)

boxplot (median, 1:a och 3:e quartil, iqr)



Inferentiell S.

- Generellt antagande: Stickprov består av n oberoende s.v., alla har samma fördelning som populationen.
- Estimator $\hat{\theta}$ för en parameter θ av populationens fördelning är en s.v. och kan vara väntevärdesriktig ($E\hat{\theta} = \theta$) och konsistent ($\text{var}(\hat{\theta}) \rightarrow 0$ med $n \rightarrow \infty$).
- Stickprovs medelvärde $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ är väntevärdesriktig^{som estimator för μ} och har varians $\frac{\sigma^2}{n}$ där $\sigma^2 = \text{var}(X_i)$, alltså konsistent.
- Stickprovs variansen $S^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1} = \frac{n \sum_{i=1}^n X_i^2 - (\sum_{i=1}^n X_i)^2}{n(n-1)}$ är väntevärdesriktig estimator för σ^2 ($E S^2 = \sigma^2$).
- För normalfördelad population (eller stort stickprov, $n \geq 25$) är $\bar{X}$ (approximativt) normalfördelad med väntevärde μ och varians σ^2
 $\Rightarrow \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$. (Centrala gränsvärdes.)
- ett symmetriskt $(1-\alpha) \cdot 100\%$ konfidenstervall för μ ges då av $\bar{x} \pm z_{\alpha/2} \frac{\sigma}{\sqrt{n}}$ där $z_{\alpha/2}$ är sådan att $P(Z > z_{\alpha/2}) = \alpha/2$ $\sim N(0, 1)$
ensidigt: $(-\infty, \bar{x} + z_{\alpha} \frac{\sigma}{\sqrt{n}})$ resp. $(\bar{x} - z_{\alpha} \frac{\sigma}{\sqrt{n}}, \infty)$.
högra vänstra svansen
- För normalfördelad population (eller stor n) är $\frac{(n-1)S^2}{\sigma^2}$ (approximativt) χ^2 -fördelad med $n-1$ frihetsgrader.
- ett symmetriskt $(1-\alpha) \cdot 100\%$ konfidenstervall för σ^2 ges då av $(\frac{(n-1)S^2}{q_{1-\alpha/2}}, \frac{(n-1)S^2}{q_{\alpha/2}})$ där q_{α} är sådan att $P(\chi^2 < q_{\alpha}) = \alpha$. $\sim \chi^2_{n-1}$
ensidigt: $[0, \frac{(n-1)S^2}{q_{\alpha}})$
- För en normalfördelad population är $\frac{\bar{X} - \mu}{S/\sqrt{n}}$ t-fördelad med $n-1$ frihetsgrader
symmetriskt $(1-\alpha) \cdot 100\%$ k.I. för μ :
 $\bar{x} \pm t_{\alpha/2} \cdot \frac{s}{\sqrt{n}}$ där $t_{\alpha/2}$ är sådan att $P(T > t_{\alpha/2}) = \alpha/2$.

Hypotesprövning

nollhypotes: $H_0: \theta = \theta_0$, $\theta \geq \theta_0$ eller $\theta \leq \theta_0$
alternativ: $H_1: \theta \neq \theta_0$, $\theta < \theta_0$ $\theta > \theta_0$
tvärsidigt ensidigt

- Väljer signifikansnivå och bedömer om nollhypotesen är rimlig eller bör förkastas (typ I fel: H_0 förkastas men stämmer, typ II fel: H_0 behålls dock fel)
- Behöver en teststatistik och dess fördelning (givet antagandet att $\theta = \theta_0$)
vanligast: $Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0,1)$ och $T = \frac{\bar{X} - \mu}{s/\sqrt{n}}$ t-fördelad med $n-1$ frihetsgrader (när det gäller $\theta = \mu$)
- om utfallet av Z inte landar i $(-z_{\alpha/2}, z_{\alpha/2})$ (tvärsidigt)
resp. $(-\infty, z_{\alpha})$ eller $(-z_{\alpha}, \infty)$ (ensidigt) förkastar vi H_0 .
 Motsvarande regioner för T : $(-t_{\alpha/2}, t_{\alpha/2})$
resp. $(-\infty, t_{\alpha})$ eller $(-t_{\alpha}, \infty)$
- P-värde: minsta signifikansnivå α på vilken H_0 förkastas.
t.ex. för teststatistik Z med utfall z_0 är det
$$P = \begin{cases} 2P(Z \leq z_0) & \text{om } z_0 \leq 0 \\ 2P(Z \geq z_0) & \text{om } z_0 > 0 \end{cases}$$
 (tvärsidigt) resp. $P = IP(Z \leq z_0)$ (vänster)
 $P = IP(Z \geq z_0)$ (höger)
(ensidigt)
(samma för andra symmetriskt fördelade)
(teststatistiker, som t.ex. T)

Proportionsskattning

- X_j : indikator om element j i stickeprovet ingår
- $\hat{p} = \frac{\sum_j X_j}{n}$ är väntevärdesriktig och konsistent estimator av proportionen p .
 - Ett symmetriskt $(1-\alpha)100\%$ konfidensintervall för p är $\hat{p} \pm z_{\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}$
 - Vill man ha max. avvikelse d från punktskattningen $\hat{p}$ i denna behövs stickeprovsstorlek $n \geq \frac{z_{\alpha/2}^2 p_0(1-p_0)}{d^2}$ med apriori värde p_0 , $n \geq \frac{z_{\alpha/2}^2}{4d^2}$ utan.
 - För hypotesprövning användes man teststatistiken $Z = \frac{\hat{p} - p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}} \sim N(0,1)$
 - Jämförelse av två populationer:
 $\hat{p}_1 - \hat{p}_2$ approx. $N(p_1 - p_2, \frac{p_1(1-p_1)}{n_1} + \frac{p_2(1-p_2)}{n_2})$
 $\rightarrow$ symmetriskt $(1-\alpha)100\%$ -KI för $p_1 - p_2$: $\hat{p}_1 - \hat{p}_2 \pm z_{\alpha/2} \sqrt{\frac{\hat{p}_1(1-\hat{p}_1)}{n_1} + \frac{\hat{p}_2(1-\hat{p}_2)}{n_2}}$
så länge min $\{n_p; n(1-p)\} > 5$

Jämförelse av medelvärden i två populationer

• $\sigma_1 \neq \sigma_2$: $\bar{X}_1 - \bar{X}_2$ (approximativt) $\mathcal{N}(\mu_1 - \mu_2, \frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2})$

$\rightarrow \bar{x}_1 - \bar{x}_2 \pm z_{\alpha/2} \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}$ symmetriskt $(1-\alpha)100\%$ -KI för $X_1 - X_2$.

• $\sigma_1 = \sigma_2 =: \sigma$ (också dölj)

kombinerad stickprovsvarians $S_p^2 = \frac{(n_1-1)S_1^2 + (n_2-1)S_2^2}{n_1+n_2-2}$
väntevärdesriktig estimator för σ^2 ,

$\frac{n_1+n_2-2}{\sigma^2} S_p^2$ χ^2 -fördelad med n_1+n_2-2 frihetsgrader.

$\frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{\sqrt{S_p^2 (\frac{1}{n_1} + \frac{1}{n_2})}}$ t-fördelad

kan användas som teststatistik eller till beräkning av ett (symmetriskt)
 $(1-\alpha) \cdot 100\%$ -KI för $\mu_1 - \mu_2$: $(\bar{x}_1 - \bar{x}_2) \pm t_{\alpha/2} \sqrt{S_p^2 (\frac{1}{n_1} + \frac{1}{n_2})}$

Linjär regression

X: förklarande variabel, Y: responsvariabel

vill hitta ett linjärt samband $\mu_{Y|X} = \beta_0 + \beta_1 \cdot x$

datamängd $\{(x_i, y_i) ; i=1 \dots n\}$

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

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

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

minsta kvadrat estimatorer

$B_1 = \frac{S_{xy}}{S_{xx}}$ är en väntevärdesriktig est. för β_1 , $B_1 \sim \mathcal{N}(\beta_1, \frac{\sigma^2}{S_{xx}})$

$B_0 = \bar{y} - B_1 \bar{x}$ " " " " β_0 , $B_0 \sim \mathcal{N}(\beta_0, \frac{\sigma^2}{n S_{xx}} \sum_i x_i^2)$

$SSE = \sum_{i=1}^n (y_i - (B_0 + B_1 x_i))^2 = S_{yy} - B_1 S_{xy}$ (sum of squared errors)

$S^2 = \frac{SSE}{n-2}$ är en väntevärdesriktig est. för σ^2 .

- $z = \frac{\beta_1 - \hat{\beta}_1}{\sigma / \sqrt{S_{xx}}} \sim N(0,1)$ eller $T = \frac{\beta_1 - \hat{\beta}_1}{S / \sqrt{S_{xx}}} \sim t$ -fördelad med $n-2$ frihetsgrader

kan användas för att bestämma konfidensintervall

$$\beta_1 \pm z_{\alpha/2} \frac{\sigma}{\sqrt{S_{xx}}} \quad \text{resp.} \quad \beta_1 \pm t_{\alpha/2} \frac{S}{\sqrt{S_{xx}}} \quad \text{eller hypotesprövning.}$$

- Samma gäller för $z = \frac{\beta_0 - \hat{\beta}_0}{\sigma \sqrt{\sum_i x_i^2 / n \cdot S_{xx}}} \sim N(0,1)$, $T = \frac{\beta_0 - \hat{\beta}_0}{S \cdot \sqrt{\frac{\sum_i x_i^2}{n \cdot S_{xx}}}} \sim t$ -fördelad med $n-2$ frihetsgrader

$$\Rightarrow \beta_0 \pm z_{\alpha/2} \sigma \sqrt{\frac{\sum_i x_i^2}{n \cdot S_{xx}}} \quad \text{resp.} \quad \beta_0 \pm t_{\alpha/2} S \cdot \sqrt{\frac{\sum_i x_i^2}{n \cdot S_{xx}}}$$

Centrala gränsvärdesatsen

$X_1, \dots, X_n$ oberoende, samma fördelning med väntevärde μ och varians σ^2
 Då är $\bar{X}$ approximativt normalfördelad med väntevärde μ och varians σ^2/n
 alltså $\frac{\bar{X} - \mu}{\sigma / \sqrt{n}} \sim N(0,1) \quad (n \geq 25).$

Chebyshev

För X med $EX = \mu$ och $\text{var}(X) = \sigma^2$ och godtyckligt $\varepsilon > 0$ gäller

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

Stora talens lag

$X_1, \dots, X_n$ oberoende, samma väntevärde μ och varians σ^2 , godtyckligt $\varepsilon > 0$

$$\Rightarrow P(|\bar{X} - \mu| \geq \varepsilon) \rightarrow 0 \quad \text{med } n \rightarrow \infty.$$