

## Empiri

I verkligheten har vi  $n$  oberoende observationer  $x_1, \dots, x_n$  av någon variabel  $x$ , som är det vi observerar när vi mäter en parameter  $\theta$ .

## Teori

I teorin har vi ett stickprov ("random sample")  $X_1, \dots, X_n$  från  $X$ 's fördelning och denna har åtminstone en okänd parameter  $\theta$ . Det kan finnas fler.

Fördelningen för  $X$  ska spegla de variationer vi ser i  $x$  då vi mäter  $\theta$ .

Om observationerna är tider, är kanske  $\text{Exp}(\lambda)$  en bra modell.

Om observationerna är någon slags mätvärden är ofta  $N(\mu, \sigma)$  en bra modell. Man tänker sig då att

$$X = \mu + \sigma \epsilon \quad \epsilon \sim N(0, 1)$$

Om man räknar ovanliga händelser i ett tidsintervall av längd  $t$  är ofta  $\text{Poi}(\lambda t)$  en bra modell. Ofta har man då bara en observation  $x$ , som alltså är antalet händelser i ett tidsintervall av längd  $t$ .

Om man vill skatta en okänd sannolikhet  $p$  ska man använda  $\text{Bin}(n, p)$ -modellen. Här observerar man

$$x = \sum_{i=1}^n x_i$$

där  $x_1, \dots, x_n$  är oberoende  $\text{Ber}(p)$ -observationer.

## Tre exempel

I syfte att estimeras tillförlitligheten av 16-kbit dynamiska RAM av ett visst fabrikat, valde man slumpmässigt ut 100 st som testades under 1000 timmars kontinuerlig drift. Man fann att  $x = 91$  av de 100 testobjekten fungerade felritt under hela testtiden. Teoretisk modell för detta försök är  $X \sim \text{Bin}(n, p)$ , där  $n = 100$  och  $p$  är sannolikheten att ett RAM av den testade typen fungerar felritt de första 1000 drifttimmarna.

Man har i 4 lika stora vattenprov nedströms en avfallsanläggning räknat antalet kolibakterier och fått

$$x_1 = 12, \quad x_2 = 15, \quad x_3 = 16, \quad x_4 = 17$$

Teoretisk modell för detta försök skulle kunna vara  $X \sim \text{Poi}(\lambda)$ .

Man har i 5 oberoende jordprov i en gammal industritomt mätt kromhalten i mg/kg och fått

$$x_1 = 237.5, \quad x_2 = 201.9, \quad x_3 = 253.6, \quad x_4 = 258.3, \quad x_5 = 216.9$$

Teoretisk modell för detta försök skulle kunna vara  $X \sim N(\mu, \sigma)$ . Även  $\ln X \sim N(\mu, \sigma)$  skulle kunna vara en bra modell.

## Ytterligare ett exempel

Man har under 1350 timmar (drygt 56 dygn) studerat belastningen  $y_i$  av ett visst tekniskt system. Under denna tidsrymd gick belastningen över en kritisk nivå  $u = 5$  sammanlagt  $n = 8$  gånger. Maximala nivåer  $x_i$  under dessa 8 överskridanden var

$$6.85 \quad 5.11 \quad 5.61 \quad 5.28 \quad 6.87 \quad 6.40 \quad 5.16 \quad 5.12$$

Teoretisk modell för detta försök skulle kunna vara att överskridandena sker enligt en Poissonprocess  $N$  med intensitet  $\lambda$  [st/dygn] och att deras resp maximala nivåer  $X$  är Paretofördelade, vilket innebär att tätheten är

$$f(x) = \frac{\alpha}{u} \left(\frac{x}{u}\right)^{-(\alpha+1)} \quad \text{för } x > u$$

för något  $\alpha > 0$ .

## Exempel: Estimator och estimat

Vi skall använda det observerade (empiriska) medelvärdet  $\bar{x}$  till att estimeras parametern  $\mu = E[X]$ . I vardagligt tal säger man ofta att man skattar  $\mu$ . Vi kallar  $\bar{x}$  för  $\mu$ 's *estimat*.

Att  $\bar{x}$  är  $\mu$ 's estimat skrivs  $\hat{\mu} = \bar{x}$ .

Motsvarande stokastiska variabel

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

kallas  $\mu$ 's *estimator*.

Att  $\bar{X}$  är vår estimator av  $\mu$  skrivs  $\hat{\mu} = \bar{X}$ .

Estimatet är alltså det uträknade (observerade) värdet, medan estimatorm är en stokastisk variabel.

I svenskan använder man ofta ordet *skattning* och sammanhanget avgör om man avser den stokastiska variabeln eller det observerade värdet.

## Definition: Estimator and estimate

A statistic used to approximate or estimate a population parameter  $\theta$  is called a *(point) estimator* for  $\theta$  and is denoted by  $\hat{\theta}$  or  $\tilde{\theta}$  or  $\theta^*$  or ...; the numerical value assumed by this statistic when evaluated for a given sample is called a *(point) estimate* for  $\theta$ .

Att statistikan  $\hat{\theta}$ , som vi använder som estimator av  $\theta$ , beror av stickprovet  $X_1, \dots, X_n$  brukar man inte skriva ut explicit.

## Exempel

Antag att vi vid  $n$  oberoende mätningar av en viss anläggnings driftstid (tiden från start till nästa produktionsstopp) erhåll medelvärdet  $\bar{x} = 732.9$  timmar. Låt  $\mu$  beteckna den förväntade (teoretiska) driftstiden. Då är 732.9 timmar vårt estimat av  $\mu$  och vi skriver

$$\hat{\mu} = 732.9$$

## Definition 7.1.1: Väntevärdesriktighet

En estimator  $\hat{\theta}$  sägs vara väntevärdesriktig för  $\theta$ , om

$$E[\hat{\theta}] = \theta$$

Det är önskvärt att en estimator  $\hat{\theta}$  har liten varians. Ju mindre  $\text{Var}[\hat{\theta}]$  är, desto bättre är estimatorm.

## Theorem 7.1.1, 7.1.2

Stickprovsmedelvärdet  $\bar{X}$  är en väntevärdesriktig estimator av  $\mu$ . Dess varians är

$$\text{Var}[\bar{X}] = \frac{\sigma^2}{n}$$

## Definition 7.1.2: Standard error of the mean

The standard deviation of  $\bar{X}$  is given by  $\sigma/\sqrt{n}$  and is called the standard error of  $\mu$ .

## Theorem 7.1.3

Stickprovsvariansen  $S^2$  är en väntevärdesriktig estimator av  $\sigma^2$ .

I exemplet med överskridandedata (se OH no 3) förekommer en parameter  $\alpha$ . Vi ska nu med två olika metoder härleda en skattning av  $\alpha$ .

## A: Momentmetoden

Vi börjar med att m.h.a.  $X$ 's täthet

$$f(x) = \frac{\alpha}{u} \left(\frac{x}{u}\right)^{-(\alpha+1)} \quad \text{för } x > u$$

beräkna

$$\mu = E[X] = \int_u^\infty x \frac{\alpha}{u} \left(\frac{x}{u}\right)^{-(\alpha+1)} dx = \dots = \frac{\alpha}{\alpha-1} u$$

Denna beräkning förutsätter att  $\alpha > 1$ , så det som följer är bara giltigt om så är fallet. Inverteras likheten

$$\mu = \frac{\alpha}{\alpha-1} u$$

får vi

$$\alpha = \frac{\mu}{\mu - u}$$

Således är momentestimatet (momentskattningen) av  $\alpha$  lika med

$$\hat{\alpha} = \frac{\bar{x}}{\bar{x} - u} = \frac{5.8}{5.8 - 5.0} = 7.25$$

Momentestimatoren av  $\alpha$  är

$$\hat{\alpha} = \frac{\hat{\mu}}{\hat{\mu} - u} = \frac{\bar{X}}{\bar{X} - u}$$

## B: Trolighetsmetoden

Vi börjar med att konstatera att täthetsens värde i punkten  $x$  är ett mått på hurpass troligt det är att vi observerar just värdet  $x$ . Att vi observerade värdena  $x_1, \dots, x_n$  i  $n$  oberoende försök blir då så här troligt:

$$\prod_{i=1}^n f(x_i) = \frac{\alpha}{u} \left(\frac{x_1}{u}\right)^{-(\alpha+1)} \dots \frac{\alpha}{u} \left(\frac{x_n}{u}\right)^{-(\alpha+1)}$$

För givna observationer  $x_1, \dots, x_n$  är detta en funktion av parametern  $\alpha$  som vi kallar trolighetsfunktionen eller bara troligheten och betecknar  $L(\alpha)$ . Här ser vi att

$$L(\alpha) = \left(\frac{\alpha}{u}\right)^n \left(\prod_{i=1}^n \frac{x_i}{u}\right)^{-(\alpha+1)}$$

Trolighetsmetodens skattning av  $\alpha$  är

$$\hat{\alpha} = \underset{\alpha}{\text{argmax}} L(\alpha)$$

Lösningen av detta maximeringsproblem är

$$\hat{\alpha} = \frac{n}{\sum_{i=1}^n \ln(x_i/u)}$$

Trolighetsestimatoren är alltså

$$\hat{\alpha} = \frac{n}{\sum_{i=1}^n \ln(X_i/u)} = \frac{1}{\frac{1}{n} \sum_{i=1}^n \ln X_i - \ln u}$$

och trolighetskattningen (trolighetsestimatet) är

$$\hat{\alpha} = \frac{1}{0.1407} \approx 7.105$$

Således:

Antag att vi har  $k$  parametrar  $\theta_1, \dots, \theta_k$  i den aktuella fördelningen för  $X$  (det som vi observerar eller mäter).

Ex 1:  $k = 1$  och  $\theta_1 = \lambda$  om  $X \sim \text{Exp}(\lambda)$

Ex 2:  $k = 2$  och  $\theta_1 = \mu, \theta_2 = \sigma$  om  $X \sim N(\mu, \sigma)$

Vår uppgift är att hitta en skattning av  $\theta = g(\theta_1, \dots, \theta_k)$ .

Momentmetoden bygger på identiteten

$$\theta = h(m_1, m_2, \dots, m_k)$$

där  $m_i = E[X^i]$  och momentskattningen av  $\theta$  är

$$\hat{\theta} = h(\hat{m}_1, \hat{m}_2, \dots, \hat{m}_k)$$

där

$$\hat{m}_j = \frac{1}{n} \sum_{i=1}^n x_i^j$$

Trolighetsmetoden maximerar trolighetsfunktionen

$$L(\theta_1, \dots, \theta_k) = \prod_{i=1}^n f(x_i)$$

och trolighetsskattningen av  $\theta_1, \dots, \theta_k$  är

$$\hat{\theta}_1, \dots, \hat{\theta}_k = \underset{\theta_1, \dots, \theta_k}{\text{argmax}} L(\theta_1, \dots, \theta_k)$$

Trolighetsskattningen av  $\theta = g(\theta_1, \dots, \theta_k)$  är  $\hat{\theta} = g(\hat{\theta}_1, \dots, \hat{\theta}_k)$ .

PS Använd i första hand trolighetsmetoden. Om detta ej går, härled din skattning på något annat sätt, t.ex med momentmetoden.

Exempel

Ur  $n = 7$  mätningar  $x_1, \dots, x_n$  har vi erhållit  $\bar{x} = 7.4$ ,  $s^2 = 4.50$  ( $s \approx 2.1213$ ). Vi ska skatta 95%-kvantilen  $x_{0.95}$  och har kommit fram till att  $X \sim N(\mu, \sigma)$  är en vettig modell. Ur definitionen  $F(x_{0.95}) = 0.95$  härleder vi  $x_{0.95} = \mu + 1.645\sigma$ .

Momentmetoden: Ur  $m_1 = \mu$ ,  $m_2 = \mu^2 + \sigma^2$  får vi  $\mu = m_1$ ,  $\sigma = \sqrt{m_2 - m_1^2}$ . Således gäller  $x_{0.95} = m_1 + 1.645\sqrt{m_2 - m_1^2}$ . Momentskattningen av 95%-kvantilen är alltså

$$\begin{aligned} \hat{x}_{0.95} &= \hat{m}_1 + 1.645\sqrt{\hat{m}_2 - \hat{m}_1^2} \\ &= 7.4 + 1.645\sqrt{58.617 - 7.4^2} = 10.63 \end{aligned}$$

ty  $\hat{m}_1 = (1/n) \sum_i x_i = \bar{x} = 7.4$ ,  $\hat{m}_2 = (1/n) \sum_i x_i^2 = (n-1)s^2/n + \bar{x}^2 = 58.617$ .

Trolighetsmetoden: Maximering av troligheten

$$L(\mu, \sigma) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} e^{-(x_i - \mu)^2/2\sigma^2} = (2\pi)^{-n/2} \sigma^{-n} e^{-(1/2)\sum_i (x_i - \mu)^2/\sigma^2}$$

ger  $\hat{\mu} = \bar{x} = 7.4$ ,  $\hat{\sigma} = \sqrt{\frac{1}{n} \sum_i (x_i - \bar{x})^2} = \sqrt{\frac{n-1}{n}} s = 1.964$ .

Trolighetsskattningen av 95%-kvantilen är alltså

$$\hat{x}_{0.95} = \hat{\mu} + 1.645\hat{\sigma} = 7.4 + 1.645 \cdot 1.964 = 10.63$$

Fast i praktiken använder man gärna den naturliga skattningen

$$\hat{x}_{0.95} = \bar{x} + 1.645s = 7.4 + 1.645 \cdot 2.1213 = 10.89$$

Theorem 7.3.1

Antag att  $X$  och  $Y$  är stokastiska variabler och med m.g.f  $m_X(t)$  och  $m_Y(t)$ . Om  $m_X(t) = m_Y(t)$  för alla  $t$  i en öppen omgivning till  $t = 0$ , så har  $X$  och  $Y$  samma fördelning.

Theorem 7.3.2

Låt  $X_1$  och  $X_2$  vara två oberoende stokastiska variabler med m.g.f  $m_{X_1}(t)$  och  $m_{X_2}(t)$ . Låt  $Y = X_1 + X_2$ . Då ges  $Y$ 's m.g.f av

$$m_Y(t) = m_{X_1}(t)m_{X_2}(t)$$

Theorem 7.3.3

Låt  $X$  vara en stokastisk variabel med m.g.f  $m_X(t)$ . Låt  $Y = \alpha + \beta X$ . Då ges  $Y$ 's m.g.f av

$$m_Y(t) = e^{\alpha t} m_X(\beta t)$$

Theorem 7.3.4: Distribution of  $\bar{X}$ —normal population

Let  $X_1, \dots, X_n$  be a random sample of size  $n$  from a normal distribution with mean  $\mu$  and standard deviation  $\sigma$ . Then  $\bar{X}$  is normally distributed with mean  $\mu$  and standard deviation  $\sigma/\sqrt{n}$ .

I exemplet med jordproverna (se OH no 2) är  $\bar{x} = 233.64$  vårt estimat av väntevärdet  $\mu$ . Antag att vi bestäm oss för modellen  $X \sim N(\mu, \sigma)$ . Estimatoren  $\bar{X}$  är enl. sats 7.3.4  $N(\mu, \sigma/\sqrt{n})$ , där  $n = 5$  är antalet observationer. Observera att för att teorin ska fungera är det väsentligt att jordproverna är oberoende.

Notera nu att

$$P\left[-1.96 \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq 1.96\right] = 0.95$$

Men olikheten

$$-1.96 \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq 1.96$$

är ekvivalent med

$$\bar{X} - 1.96\sigma/\sqrt{n} \leq \mu \leq \bar{X} + 1.96\sigma/\sqrt{n}$$

Således gäller

$$P[\bar{X} - 1.96\sigma/\sqrt{n} \leq \mu \leq \bar{X} + 1.96\sigma/\sqrt{n}] = 0.95$$

Anta att det är känt att  $\sigma = 30$  för den här typen av analyser. Då är  $1.96\sigma/\sqrt{n} = 26.30$  och vi får intervallskattningen

$$(233.64 - 26.30) \leq \mu \leq 259.94 \quad (= 233.64 \pm 26.30)$$

Intervall [207.34, 259.94] är ett konfidensintervall för  $\mu$  med konfidensgraden 95%.

Ofta skriver man

$$\mu = 233.64 \pm 26.30$$

## Definition 7.4.1: Confidence interval

A  $100(1 - \alpha)\%$  confidence interval for a parameter  $\theta$  is a random interval  $[L_1, L_2]$  such that

$$P[L_1 \leq \theta \leq L_2] = 1 - \alpha$$

regardless of the value of  $\theta$ .

To construct a  $100(1 - \alpha)\%$  confidence interval for a parameter  $\theta$ , we shall find a random variable whose expression involves  $\theta$  and whose probability distribution is known (at least approximately).

Theorem 7.4.1:  $100(1 - \alpha)\%$  confidence interval on  $\mu$  ( $\sigma$  known)

Let  $X_1, \dots, X_n$  be a random sample of size  $n$  from a normal distribution with mean  $\mu$  and standard deviation  $\sigma$ . A  $100(1 - \alpha)\%$  confidence interval on  $\mu$  when  $\sigma$  is known, is given by

$$\mu = \bar{X} \pm z_{\alpha/2} \sigma / \sqrt{n}$$

where the quantile  $z_{\alpha/2}$  is determined by the requirement

$$P[Z > z_{\alpha/2}] = \alpha/2$$

for  $Z \sim N(0, 1)$ .

Ibland vill man ha ett ensidigt konfidensintervall av typen  $\theta < L$ .

I normalfördelningsfallet utgår man då ifrån

$$P \left[ -z_\alpha < \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \right] = 1 - \alpha$$

och härleder

$$P \left[ \mu < \bar{X} + z_\alpha \sigma / \sqrt{n} \right] = 1 - \alpha$$

I jordprovsexemplet (se OH no 2 och 12) får vi (med  $\sigma = 30$ ) om  $\alpha = 0.05$  att  $z_\alpha = 1.645$  vilket ger  $z_\alpha \sigma / \sqrt{n} = 22.07$  och intervallstimatet med konfidens 95% blir

$$\mu \leq 255.71 \quad (= 233.64 + 22.07)$$

J.f.r med

$$\mu = 233.64 \pm 26.30 \quad \Leftrightarrow \quad 207.34 \leq \mu \leq 259.94$$

## Theorem 7.4.2: Central Limit Theorem

Let  $X_1, \dots, X_n$  be a random sample of size  $n$  from a distribution with mean  $\mu$  and standard deviation  $\sigma$ . Then for large  $n$ ,  $\bar{X}$  is approximately normal with mean  $\mu$  and standard deviation  $\sigma/\sqrt{n}$ . Hence for large  $n$ , the standardized random variable

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$$

is approximately standard normal.

Men, då  $n$  är stort, gäller även att  $s \approx \sigma$  och följaktligen har vi då också att

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

Denna approximation är naturligtvis sämre än den i sats 7.4.2.

Normalapproximation av  $\text{Bin}(n, p)$ 

Här är  $X_1, \dots, X_n$  ett stickprov på  $\text{Ber}(p)$ .

Då är  $\mu = p$  och  $\sigma^2 = p(1 - p)$ .

Enl c.g.s är  $\bar{X}$  approximativt  $N \left( p, \sqrt{\frac{p(1-p)}{n}} \right)$  då  $n$  är stort.

Men då är också  $S = \sum_{i=1}^n X_i$  approximativt  $N(np, \sqrt{np(1-p)})$ .

Notera också att  $S \sim \text{Bin}(n, p)$ .

Således gäller att  $\text{Bin}(n, p) \approx N(np, \sqrt{np(1-p)})$ .

Hur stort behöver  $n$  vara för att approximationen ska fungera?

Milton & Arnold, sida 121 (avs 4.6): "For most practical purposes the approximation is acceptable for values of  $n$  and  $p$  such that either  $p \leq 0.5$  and  $np > 5$  or  $p > 0.5$  and  $n(1 - p) > 5$ ."

M.a.o är  $n \min(p, 1 - p) > 5$  en lämplig regel.

Se exempel 4.6.1.