

Parameterskattningar

1

Punktskattning

Låt x_1, \dots, x_n vara observationer av oberoende s.v X_1, \dots, X_n vars sannolikhetsfunktion $p(k, \theta)$ el. täthetsfunktion $f(x, \theta)$ innehåller en okänd parameter θ .

\Rightarrow vi söker ett approximativt värde på θ , dvs en punktskattning.

- θ : verkligt värde
- $\hat{\theta}$: approximativt värde (skattning)
- $\hat{\Theta}$: stokastisk variabel (hur skattningen, $\hat{\theta}$, varierar)

Väntevärdesriktig skattning (vvr):

En skattning är vvr om:

$$E(\hat{\theta}) = \theta$$

$$E(\hat{\theta}^2) = \sigma^2$$

Effektiva skattningar:

Om både $\hat{\theta}_1$ & $\hat{\theta}_2$ är vvr skattningar är $\hat{\theta}_1$ effektivare än $\hat{\theta}_2$ om:

$$\text{var}(\hat{\theta}_1) < \text{var}(\hat{\theta}_2)$$

Skattningar som ofta används:

$$\hat{\mu} = \bar{x}$$

$$\hat{\sigma}^2 = s^2 \quad \text{där } \sigma^2 \text{ är varians} \text{ } \text{ } s^2 \text{ är stickprovsvarians}$$

$$\sigma^2 = \frac{1}{n} \left(\sum_{i=1}^n (x_i - \mu)^2 \right)$$

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

Repetition:

$$V(\bar{X}) = E(\bar{X}^2) - E(\bar{X})^2$$

$$E(a\bar{X} + b) = aE(\bar{X}) + b$$

$$V(a\bar{X} + b) = a^2 V(\bar{X})$$

Exempel: vvr samt mest effektiv

Stickprov: x_1, \dots, x_n

$\bar{X} \sim N(\mu, \sigma)$ där μ o σ är okända

Det finns 2 olika skattningar på μ :

$$\boxed{1}: \hat{\mu}_1 = \bar{X} = \frac{1}{n} \sum_{i=1}^n x_i$$

$$\boxed{2}: \hat{\mu}_2 = \frac{x_1 + x_n}{2}$$

Är $\hat{\mu}_1$ o $\hat{\mu}_2$ vvr?

$$\begin{aligned} \boxed{1}: E(\hat{\mu}_1) &= E(\bar{X}) = E\left(\frac{1}{n} \sum_{i=1}^n \bar{x}_i\right) = \frac{1}{n} E\left(\sum_{i=1}^n \bar{x}_i\right) = \frac{1}{n} \sum_{i=1}^n E(\bar{x}_i) = \\ &= \frac{1}{n} \cdot n \cdot \underbrace{E(\bar{x}_i)}_{=\mu} = \frac{n}{n} \cdot \mu = \mu \Rightarrow \text{vvr!} \end{aligned}$$

$$\begin{aligned} \boxed{2}: E(\hat{\mu}_2) &= E\left(\frac{\bar{x}_1 + \bar{x}_n}{2}\right) = \frac{1}{2} E(\bar{x}_1 + \bar{x}_n) = \frac{1}{2} \left(\underbrace{E(\bar{x}_1)}_{=\mu} + \underbrace{E(\bar{x}_n)}_{=\mu} \right) = \\ &= \frac{1}{2} (\mu + \mu) = \frac{1}{2} (2\mu) = \mu \Rightarrow \text{vvr!} \end{aligned}$$

Vilken skattning är mest effektiv?

$$\begin{aligned} \boxed{1}: V(\hat{\mu}_1) &= V(\bar{X}) = V\left(\frac{1}{n} \sum_{i=1}^n \bar{x}_i\right) = \frac{1}{n^2} V\left(\sum_{i=1}^n \bar{x}_i\right) = \frac{1}{n^2} \sum_{i=1}^n \underbrace{V(\bar{x}_i)}_{=\sigma^2} = \\ &= \frac{1}{n^2} \cdot n \cdot \sigma^2 = \frac{\sigma^2}{n} \end{aligned}$$

$$\begin{aligned} \boxed{2}: V(\hat{\mu}_2) &= V\left(\frac{\bar{x}_1 + \bar{x}_n}{2}\right) = \frac{1}{4} V(\bar{x}_1 + \bar{x}_n) = \frac{1}{4} \left(\underbrace{V(\bar{x}_1)}_{=\sigma^2} + \underbrace{V(\bar{x}_n)}_{=\sigma^2} \right) = \\ &= \frac{1}{4} (\sigma^2 + \sigma^2) = \frac{1}{4} (2\sigma^2) = \frac{\sigma^2}{2} \end{aligned}$$

då $n > 2$ fås:

$$\frac{\sigma^2}{n} < \frac{\sigma^2}{2} \Rightarrow \hat{\mu}_1 \text{ är mer effektiv!}$$

Konsistent skattning

2

Om $E(\hat{\theta}_n) = \theta$ och $\text{var}(\hat{\theta}_n) \rightarrow 0$ då $n \rightarrow \infty$
så är $\hat{\theta}_n$ en konsistent skattning av θ .

Miniräknare

Ska kunna hitta s , kolla upp hur

Minsta-kvadrat-metoden

Låt x_1, \dots, x_n vara observationer av oberoende s.v. X_1, \dots, X_n

med $E(X_i) = \mu_i(\theta)$ och $\text{var}(X_i) = \sigma^2$

Det värde $\hat{\theta}$ som minimerar:

$$Q(\theta) = \sum_{i=1}^n (x_i - \mu_i(\theta))^2$$

kallas för minsta-kvadrat-skattning

Exempel - Normalfördelning

x_1, \dots, x_n observationer av oberoende s.v. X_1, \dots, X_n

$X_i \sim N(\mu, \sigma)$, σ är känt

skatta μ med minsta-kvadrat-metoden:

$$Q(\mu) = \sum_{i=1}^n (x_i - \mu)^2$$

$$\frac{dQ}{d\mu} = -2 \sum_{i=1}^n (x_i - \mu) = 0 \iff 0 = \sum_{i=1}^n (x_i - \mu) = \sum_{i=1}^n x_i - n\mu$$

$$\text{vilket ger } \hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i = \bar{X}$$

Maximum-Likelihood-Metoden

Maximum-Likelihood-funktionen

$$\begin{array}{l} \text{Diskret: } L(\theta) = \prod_{i=1}^n P(X_i = x_i; \theta) \\ \text{Kontinuerlig: } L(\theta) = \prod_{i=1}^n f_{X_i}(x_i; \theta) \end{array} \left. \vphantom{\begin{array}{l} \text{Diskret: } L(\theta) = \prod_{i=1}^n P(X_i = x_i; \theta) \\ \text{Kontinuerlig: } L(\theta) = \prod_{i=1}^n f_{X_i}(x_i; \theta) \end{array}} \right\} \begin{array}{l} \text{sannolikheten att} \\ \text{alla h\u00e4ndelser h\u00e4nder} \end{array}$$

Det v\u00e4rde $\hat{\theta}$ som maximerar $L(\theta)$ kallas f\u00f6r maximum-likelihood-skattningen (ML-skattningen) av θ .

Anm\u00e4rkning: Vid maximering av $L(\theta)$ ska θ betraktas som en variabel \ominus x_i som konstant.

Anm\u00e4rkning: Det \u00e4r oftast enklare att maximera

$$\Rightarrow \ln L(\theta) = \sum_{i=1}^n \ln f(x_i; \theta)$$

Repetition Logaritmlagar:

$$\ln(xy) = \ln(x) + \ln(y) \Rightarrow \ln\left(\prod_{i=1}^n x_i\right) = \ln(x_1 \cdot \dots \cdot x_n) = \sum_{i=1}^n \ln x_i$$

$$\ln x^y = y \ln x$$

$$\ln\left(\frac{x}{y}\right) = \ln(x) - \ln(y)$$

$$\ln e = 1$$

Exempel:

$$f_X(x) = \frac{x}{a} e^{-\frac{x^2}{2a}}, \quad x \geq 0$$

Ange ML-skattningen av a :

(I) st\u00e4ll upp maximum-likelihood-funktionen

$$L(a) = \prod_{i=1}^n f_X(x_i) = \frac{x_1}{a} \cdot e^{-\frac{x_1^2}{2a}} \cdot \dots \cdot \frac{x_n}{a} e^{-\frac{x_n^2}{2a}} = \left(\frac{1}{a}\right)^n \cdot \prod_{i=1}^n x_i \cdot e^{-\frac{1}{2a} \sum_{i=1}^n x_i^2}$$

(II) Logaritmera funktionen

$$\begin{aligned}
 l(a) &= \ln(L(a)) = \ln\left(\left(\frac{1}{a}\right)^n \cdot \prod_{i=1}^n x_i \cdot e^{-\frac{1}{2a} \sum_{i=1}^n x_i^2}\right) = \\
 &= \ln\left(\frac{1}{a^n}\right) + \ln\left(\prod_{i=1}^n x_i\right) + \ln\left(e^{-\frac{1}{2a} \sum_{i=1}^n x_i^2}\right) = \\
 &= -n \ln a + \sum_{i=1}^n \ln x_i + \underbrace{-\frac{1}{2a} \sum_{i=1}^n x_i^2}_{=1} \cdot \underbrace{\ln e}_{=1} =
 \end{aligned}$$

(III) Derivera med avseende på a :

$$\frac{dl}{da} = -\frac{n}{a} + \frac{1}{2a^2} \cdot \sum_{i=1}^n x_i^2 = 0$$

$$\Leftrightarrow \frac{1}{2a^2} \sum_{i=1}^n x_i^2 = \frac{n}{a} \Leftrightarrow \boxed{a = \frac{1}{2n} \sum_{i=1}^n x_i^2}$$

Den optimala skattningen blir då $\hat{a} = \frac{\sum_{i=1}^n x_i^2}{2n}$

(IV) Visa att det är en maximipunkt:

- Teckentabell
- studera andraderivatans, ska vara < 0

Repetition summor o produkter:

Summor:

$$\sum_{i=1}^n x_i = x_1 + x_2 + \dots + x_n$$

$$\sum_{i=1}^n ax_i = ax_1 + ax_2 + \dots + ax_n = a(x_1 + x_2 + \dots + x_n) = a \sum_{i=1}^n x_i$$

$$\sum_{i=1}^n c = n \cdot c$$

Produkter:

$$\prod_{i=1}^n x_i = x_1 \cdot x_2 \cdot \dots \cdot x_n$$

$$\prod_{i=1}^n ax_i = (ax_1) \cdot (ax_2) \cdot \dots \cdot (ax_n) = a^n \cdot (x_1 \cdot x_2 \cdot \dots \cdot x_n) = a^n \cdot \prod_{i=1}^n x_i$$

Konfidensintervall

Problem: Hur nära det sanna värdet hamnar $\hat{\theta}$?

Lösning: Vi kan beräkna en intervallskattning

Konfidensgrad: $1 - \alpha$ där α är risk för fel.

andelen $(1 - \alpha)$ av intervallen kommer innehålla θ

Konstruera ett konfidensintervall

(I) Bestäm $\hat{\theta}$

Använd dig av lämplig punktskattning.

(II) Ta fram fördelningen för motsvarande s.v. $\hat{\theta}$:

Konstruera m.h.a. $\hat{\theta}$ en hjälpvariabel som innehåller θ men inga andra okända parametrar och som har en "känd" fördelning.

(III) Stäng in hjälpvariablerna i ett intervall med sannolikhetsmassa $1 - \alpha$.

(IV) Skriv om intervallet i (III) till ett villkor på θ :

$$\Rightarrow P(a_1(X_1, \dots, X_n) < \theta < a_2(X_1, \dots, X_n)) = 1 - \alpha$$

(V) sätt in observationerna, beräkna:

$$I_{\theta}^{1-\alpha} = (a_1(x_1, \dots, x_n), a_2(x_1, \dots, x_n))$$

Exempel: Normalfördelning

x_i : 151320 149832 150458 150020 149263
149908 149395 150956 150003

$\sigma = 442$, konfidensgrad = 0,95

$I_{\mu}^{0,95}$ sökt , $X_i \sim N(\mu, \sigma)$

(I) Bestäm $\hat{\mu}$:

$$\hat{\mu} = \bar{x} = 150128,33$$


(II) $\bar{X} \sim N(\mu, \sigma/\sqrt{n})$, där $n=9$ (Fördelning) 4

ger hjälpvariabeln:

$$\bar{Z} = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0,1)$$

För konstruktion av I_μ då σ är känt

(III) Instängning



$$\text{ty } \alpha = 0,05$$

$$\Phi(a) = \underbrace{0,975}_{=\lambda_a}, \text{ tabell ger } a = 1,96$$

Vi får då:

$$P\left(-a < \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} < a\right) = P\left(-1,96 < \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} < 1,96\right) = 0,95$$

\uparrow konfidenzgraden

(IV) Skriv om intervallet:

$$\begin{aligned} P\left(-1,96 < \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} < 1,96\right) &= P\left(-1,96 \frac{\sigma}{\sqrt{n}} < \bar{X} - \mu < 1,96 \frac{\sigma}{\sqrt{n}}\right) = \\ &= P\left(\bar{X} - 1,96 \frac{\sigma}{\sqrt{n}} < \mu < \bar{X} + 1,96 \frac{\sigma}{\sqrt{n}}\right) = \\ &= P\left(a_1(\bar{X}_1, \dots, \bar{X}_n) < \mu < a_2(\bar{X}_1, \dots, \bar{X}_n)\right) = 0,95 \end{aligned}$$

(V) Beräkna I_μ :

$$\begin{aligned} I_\mu &= \left(\bar{X} - 1,96 \frac{\sigma}{\sqrt{n}} ; \bar{X} + 1,96 \frac{\sigma}{\sqrt{n}} \right) = \\ &= \left(150128,33 - 1,96 \cdot \frac{442}{\sqrt{9}} ; 150128,33 + 1,96 \cdot \frac{442}{\sqrt{9}} \right) = \\ &= (149839,56 ; 150417,1066) \approx (149840 ; 150420) \end{aligned}$$

$$\text{Svar: } I_\mu^{0,95} = (149840 ; 150420)$$

Två "nya" fördelningar

Dessa två fördelningar används ofta vid konstruktion av konfidensintervall:

- χ^2 -fördelning
⇒ används vid konstruktion av konfidensintervall för σ d. σ^2
- t-fördelning
⇒ används vid konstruktion av konfidensintervall för μ när σ^2 är okänd.

χ -fördelning:

En s.v. X med täthetsfunktion av typen

$$f(x) = k \cdot x^{f/2-1} \cdot e^{-x/2}, \quad x > 0$$

kallas χ^2 -fördelad med frihetsgraden f .

$$\Rightarrow X \sim \chi^2(f)$$

Om X o Y är oberoende, $X \sim \chi^2(f_1)$ o $Y \sim \chi^2(f_2)$ gäller:

$$X + Y \sim \chi^2(f_1 + f_2)$$

Sats:

Om X_1, \dots, X_n är oberoende o $X_i \sim N(\mu, \sigma)$ gäller:

$$\bullet \sum_{i=1}^n \left(\frac{X_i - \mu}{\sigma} \right)^2 \sim \chi^2(n)$$

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

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

• \bar{X} o S^2 är oberoende s.v.

Exempel χ^2 -fördelad

5

vi söker I_σ , vill veta om $\sigma = 442$ är rimligt.
 σ är alltså okänt.

(I) Bestäm s

$$s = \sqrt{\frac{1}{9-1} \sum_{i=1}^9 (x_i - \bar{x})^2} = 676.76$$

(II) Sätt upp fördelning samt skapa hjälpvariabel


$$\frac{8s^2}{\sigma^2} \sim \chi^2(8)$$

Hjälpvariabeln blir:

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

(III) Instängning

$$F(b) = 0,025 \text{ ger } b = 2,18 \quad F(c) = 0,975 \text{ ger } c = 17,55$$



$$P\left(2,18 < \frac{8s^2}{\sigma^2} < 17,55\right) = 0,95$$

(IV) Skriv om intervall till villkor för σ^2

$$P\left(2,18 < \frac{8s^2}{\sigma^2} < 17,55\right) = 0,95 \Leftrightarrow$$

$$\Leftrightarrow P\left(\frac{8s^2}{17,55} < \sigma^2 < \frac{8s^2}{2,18}\right) = 0,95$$

(V) Sätt in observationer och beräkna:

$$I_\sigma = \left(s \sqrt{\frac{8}{17,55}} ; s \sqrt{\frac{8}{2,18}}\right) \approx (457 ; 1296)$$

\Rightarrow med 95% sannolikhet ligger $457 < \sigma < 1296$

dä $442 \notin I_\sigma$ är det inte speciellt fridigt att $\sigma = 442$.

t-fördelning:

En s.v \bar{X} kallas t-fördelad med frihetsgraden f om täthetsfunktionen är av typen:

$$f(x) = c \cdot \frac{1}{\left(\frac{1+x^2}{f}\right)^{(f+1)/2}}$$

En $t(f)$ -fördelning konvergerar mot $N(0,1)$ -fördelning då $f \rightarrow \infty$

Sats:

Om $\bar{X} \in \mathcal{D}$ är oberoende $\bar{X} \sim N(0,1)$, $\mathcal{Y} \sim \chi^2(f)$ så gäller att:

$$\frac{\bar{X}}{\sqrt{\mathcal{Y}/f}} \sim t(f)$$

Denna sats används när vi tar fram hjälpvariabeln.

Exempel: t-fördelning


konfidenstervall för μ när σ är okänt.

(I) Gjort tidigare i exemplet.

(II) Konstruera hjälpvariabel:

$$\frac{\bar{X} - \mu}{s/\sqrt{n}} \sim t(n-1)$$

(III) $F(t) = 0,975$, $f = n-1 = 8$ tabell ger $t = 2,31$



$$P\left(-2,31 < \frac{\bar{X} - \mu}{s/\sqrt{n}} < 2,31\right) = 0,95$$

(IV) lös ut för μ som i tidigare exempel.

$$(V) I_{\mu} = \left(\bar{x} \pm 2,31 \cdot \frac{s}{\sqrt{n}} \right) \approx (149610, 150650)$$

Svar: $149610 < \mu < 150650$

Prediktionsintervall

$$X_0 - \bar{X} \sim N\left(0, \sigma \sqrt{1 + \frac{1}{n}}\right)$$

Hjälpsvariabel:

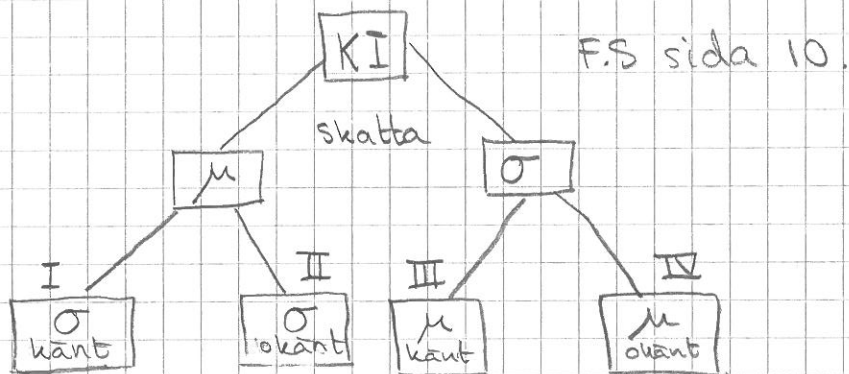
$$\frac{X_0 - \bar{X}}{\sigma \sqrt{1 + \frac{1}{n}}} \sim t(n-1)$$

Instängning ger:

$$P\left(\bar{X} - t_{\alpha} \sqrt{1 + \frac{1}{n}} < X_0 < \bar{X} + t_{\alpha} \sqrt{1 + \frac{1}{n}}\right) = 1 - \alpha$$

Vi får prediktionsintervallet:

$$I_{X_0} = \left(\bar{X} - t_{\alpha} \sqrt{1 + \frac{1}{n}} ; \bar{X} + t_{\alpha} \sqrt{1 + \frac{1}{n}}\right)$$

Konfidensintervall bild:


I: hjälpsvariabel $\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0,1)$, $I_{\mu} = (\bar{X} \pm \lambda_{\alpha/2} \cdot \sigma/\sqrt{n})$

II: hjälpsvariabel $\frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t(n-1)$, $I_{\mu} = (\bar{X} \pm t_{\alpha/2}(t) S/\sqrt{n})$


III: hjälpsvariabel $\frac{n \hat{\sigma}^2}{\sigma^2} \sim \chi^2(n-1)$, $\hat{\sigma}^2 = \frac{\sum_{i=1}^n (X_i - \mu)^2}{n}$

IV: hjälpsvariabel $\frac{(n-1)S^2}{\sigma^2} \sim \chi^2(n-1)$


Tre fall för instängning av hjälpvariabel:



Tvåsidigt



Ensidigt uppåt-begränsat



Ensidigt nedåt-begränsat

Exempel:

- Uppåt begränsat

$$P\left(\frac{\bar{X} - \mu}{S/\sqrt{n}} > -b\right) = 1 - \alpha \text{ ger intervallet } \Rightarrow I_{\mu} = \left(-\infty, \bar{x} + b \frac{S}{\sqrt{n}}\right)$$

- Nedåt begränsat

$$P\left(\frac{\bar{X} - \mu}{S/\sqrt{n}} < b\right) = 1 - \alpha \text{ ger intervallet } \Rightarrow I_{\mu} = \left(\bar{x} - b \frac{S}{\sqrt{n}}; \infty\right)$$

- tvåsidigt

$$P\left(-a < \frac{\bar{X} - \mu}{S/\sqrt{n}} < a\right) = 1 - \alpha \Rightarrow I_{\mu} = \left(\bar{x} \pm b \frac{S}{\sqrt{n}}\right)$$

Konfidenzintervall för parvisa mätningar

(I) I_{μ_1, μ_2} då $\sigma_1 \neq \sigma_2$ är kända:

Här är $\mu_1 \neq \mu_2$ olika o liksom $\sigma_1 \neq \sigma_2$. Vi söker I_{μ_1, μ_2} :

- Punktskattning: $\hat{\mu}_1, \hat{\mu}_2 = \bar{X} - \bar{Y}$

- Fördelning: Normalfördelning ty två oberoende s.v

$\bar{X} - \bar{Y}$ är en kombination av oberoende normalvariabler

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

- hjälpvariabel: $\frac{\bar{X} - \bar{Y} - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \sim N(0, 1)$

(II) I_{μ_1, μ_2} då $\sigma_1 = \sigma_2 = \sigma$ (okänd men samma)

vi söker:

1. I_{σ} el. I_{σ^2}

2. I_{μ_1, μ_2}

3. $I_{c_1\mu_1 + c_2\mu_2}$

Täthetsfunktionerna är förskjutna

i förhållande till varandra men

de har samma form.

- Om vi söker I_{σ^2} & I_{σ^2} :

$$S^2 = \frac{(n_1-1)S_1^2 + (n_2-1)S_2^2}{(n_1-1) + (n_2-1)} \quad \text{F.S. sid. 11}$$

$$\Rightarrow \frac{(n_1+n_2-2)S^2}{\sigma^2} \sim \chi^2(n_1+n_2-2) \quad \text{F.S. sid. 11}$$

- Om vi söker I_{μ_1, μ_2} :

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

- Om vi söker $I_{c_1\mu_1 + c_2\mu_2}$:

$$\boxed{\sigma_1 = \sigma_2 = \text{okända}}$$

$$\frac{c_1\bar{X} + c_2\bar{Y} - (c_1\mu_1 + c_2\mu_2)}{S \sqrt{\frac{c_1^2}{n_1} + \frac{c_2^2}{n_2}}} \sim t(n_1+n_2-2)$$

$$\boxed{\sigma_1 \neq \sigma_2, \text{okända}}$$

$$\frac{\bar{X} - \bar{Y} - (\mu_1 - \mu_2)}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}} \sim t(v)$$

$$\text{där } v = \frac{\left(\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}\right)^2}{\frac{(S_1^2/n_1)^2}{n_1-1} + \frac{(S_2^2/n_2)^2}{n_2-1}}$$

F-fördelning:

Vid jämförelse av varianser behöver vi F-fördelning.

Kommer användas i samband med regressionsanalys. (variansanalys)

Om $\Sigma_1 \circ \Sigma_2$ är oberoende $\Sigma_1 \sim \chi^2(r_1) \circ \Sigma_2 \sim \chi^2(r_2)$

så gäller:

$$v = \frac{\Sigma_1/r_1}{\Sigma_2/r_2} \sim F(r_1, r_2)$$

$$\text{Anm: } \frac{1}{v} \sim F(r_2, r_1)$$

Centrala gränsvärdesatsen

X_1, \dots, X_n är observationer av oberoende lika fördelade
s.v X_1, \dots, X_n som inte är normalfördelade.

om:

• $X \sim \text{hyp}(N, n, p)$ o $\frac{N-n}{N-1} np(1-p) \geq 10$

gäller $\Rightarrow X \approx N(np, \sqrt{\frac{N-n}{N-1} np(1-p)})$

• $X \sim \text{Bin}(n, p)$ o $np(1-p) \geq 10$

gäller $\Rightarrow X \approx N(np, \sqrt{np(1-p)})$

centrala gränsvärdesatsen säger:

• $\frac{X_n - \mu}{\sigma/\sqrt{n}} \approx N(0, 1)$

• $\bar{X}_n \approx N\left(\mu, \frac{\sigma}{\sqrt{n}}\right)$

• $\sum_{j=1}^n X_j \approx N(n\mu, \sqrt{n}\sigma)$

Hypotesprövning

När man bildar konfidensintervall vill man dra slutsatser om intressanta parametrar. Kallas signifikansstest eller hypotesprövning.

Vi vill pröva en nollhypotes mot en mothypotes:

$$H_0: \theta = \theta_0$$

$$H_1: \theta \neq \theta_0 \quad <, >$$

Det finns två typer av fel:

- Fel av typ I:

H_0 förkastas fast än H_0 är sann

α = risk för fel I

Vi vill att risken att vi slänger en hypotes som är sann ska vara så liten som möjligt

- Fel av typ II:

H_0 förkastas inte fast än H_0 är falsk

β = risk för fel II.

Vi vill att risken att vi sparar en hypotes som är falsk är så liten som möjligt.

Signifikansnivå:

$$\alpha = P(H_0 \text{ förkastas trots att } H_0 \text{ är sann})$$

α ska vara så lågt som möjligt

Styrka:

För θ_1 :

$$h(\theta_1) = P(H_0 \text{ förkastas då } \theta = \theta_1)$$

hög styrka \Rightarrow bra

$$\beta = 1 - h(\theta_1)$$

Styrkefunktionen:

Beroende på vad θ är så kommer testet vara olika "starkt"

$$h(\theta) = P(H_0 \text{ förkastas då } \theta \text{ är det sanna värdet})$$

P-värde:

P = sannolikheten, givet H_0 , att få ett visst värde/utfall.

$P < \alpha \Rightarrow$ Förlasta

$P > \alpha \Rightarrow$ Förlasta ej

Exempel:

$$\bar{X} \sim N(\mu; 0.2)$$

$$H_0: \mu = 4.0$$

$$H_1: \mu \geq 4.0$$

$$\alpha = 0,05$$

10 mätningar gav $\bar{X} = 4.1$

$0,05 = P(H_0 \text{ förlastas trots } H_0 \text{ är sann})$

$$\bar{X} \sim N(\mu, 0.2/\sqrt{n})$$

$$Z = \frac{\bar{X} - \mu}{0.2/\sqrt{n}} \sim N(0,1)$$

$$P(Z > a | H_0 \text{ sann}) = 0,05$$

$$P(Z < a) = 0,95 = \Phi(a)$$

$\Rightarrow a = 1,645$ från tabell

\therefore Sannolikheten att $Z > 1,645$ är $0,05\%$, givet $H_0 = \text{sann}$ samt $\mu = 4.0$

studera nu utfallet:

$$\bar{X} = 4.1, n = 10, \mu = 4$$

$$Z = \frac{\bar{X} - \mu}{0.2/\sqrt{n}} = \frac{4.1 - 4}{0.2/\sqrt{10}} \approx 1,5811 < 1,645$$

$\rightarrow H_0$ kan inte förlastas.

Multivariat normal fördelning

Beroendemätt

Som beroendemätt används ofta kovarians & korrelation.

Kovarians:

$$\text{cov}(X, Y) = E[(X - \mu_x)(Y - \mu_y)]$$

Korrelation:

$$\rho(X, Y) = \frac{\text{Cov}(X, Y)}{\sqrt{\text{var}(X)\text{var}(Y)}}$$

F.S sid 7

Stokastiska vektorer:

$$\underline{Y} = \begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix} = A \underline{X} + b$$

$$\begin{cases} E(\underline{Y}) = A E(\underline{X}) + b \\ C_y = A C_x A^T \end{cases}$$

$$\underline{Y} \sim N(E(\underline{Y}), C_y)$$

Linjärkombination:

$$Z = a_1 X_1 + \dots + a_n X_n$$

$$\text{var}(Z) = C_z = (a_1, \dots, a_n) \begin{pmatrix} X_1 \\ \vdots \\ X_n \end{pmatrix} \begin{pmatrix} a_1 \\ \vdots \\ a_n \end{pmatrix}$$

Korrelation ρ

$$\rho = \frac{\text{Cov}(X, Y)}{\sqrt{\text{var}(X)\text{var}(Y)}}$$

$$\begin{cases} \rho \sigma_1 \sigma_2 = \text{kovariansen} \\ \sigma_i^2 = \text{var}(X) \text{ i } C \end{cases}$$

$$C = \begin{pmatrix} \sigma_1^2 & \rho \sigma_1 \sigma_2 \\ \rho \sigma_1 \sigma_2 & \sigma_2^2 \end{pmatrix} \quad \text{kovariansmatris}$$

om X & Y är oberoende är $\rho = 0$

$\Rightarrow C$ blir en diagonalmatris

om X & Y är oberoende & likafördelade

$$\Rightarrow C = \begin{pmatrix} \sigma^2 & & \\ & \ddots & \\ & & \sigma^2 \end{pmatrix} = \sigma^2 I$$

Flera dimensioner N , täthetsfunktionen:

$$f(\underline{y}) = \frac{1}{\sqrt{2\pi}^n \sqrt{|\det C|}} \cdot e^{-\frac{1}{2}(\underline{y}-\underline{\mu})^T C^{-1}(\underline{y}-\underline{\mu})}$$

Exempel:

$X_1, X_2 \sim N(0,1) \Rightarrow$ oberoende & likafördelade

$$\underline{Y} = \begin{pmatrix} Y_1 \\ Y_2 \end{pmatrix} = \begin{pmatrix} X_1 - 2X_2 \\ X_1 + cX_2 \end{pmatrix}$$

a) Ange \underline{Y} 's fördelning

b) Bestäm c så Y_1 & Y_2 är oberoende.

a) (I) Bestäm A

$$\underline{Y} = \underbrace{\begin{pmatrix} 1 & -2 \\ 1 & c \end{pmatrix}}_A \begin{pmatrix} X_1 \\ X_2 \end{pmatrix}$$

(II) Bestäm $E(\underline{Y})$

$$E(\underline{Y}) = A E(\underline{X})$$

dä $E(\underline{X}) = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$ fås

$$E(\underline{Y}) = \begin{pmatrix} 1 & -2 \\ 1 & c \end{pmatrix} \begin{pmatrix} 0 \\ 0 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

(III) Bestäm C_Y

$$C_Y = A C_X A^T$$

$C_X = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} = I$ ty $X_1, X_2 \sim N(0,1)$ oberoende & likafördelade

$$C_Y = \begin{pmatrix} 1 & -2 \\ 1 & c \end{pmatrix} \begin{pmatrix} 1 & 1 \\ -2 & c \end{pmatrix} = \begin{pmatrix} 5 & 1-2c \\ 1-2c & 1+c^2 \end{pmatrix}$$

$$\text{svar: } \underline{Y} \sim N\left(\begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 5 & 1-2c \\ 1-2c & 1+c^2 \end{pmatrix}\right)$$

b) C_Y ska då vara en diagonalmatris, $1-2c=0$:

$$1-2c=0 \Rightarrow c = \frac{1}{2}$$

svar: $c = 1/2$

Linjär algebra repetition:

10

- Inversen

$$A = \begin{pmatrix} a & b \\ c & d \end{pmatrix}^{-1} \Rightarrow \frac{1}{\det A} \begin{pmatrix} d & -b \\ -c & a \end{pmatrix}$$

Regressionsanalys