

Kapitel 6: "Descriptive Statistics"

(Detta kapitel handlar mest om grafiskt)
äskrädliggöra ett datamaterial.

(Kapitlet är klart enklast i boken.)

Det finns fyra olika grafiska metoder lära:

- 1) "Steam-and-leaf diagram" = stam-och-blad plot
- 2) "Ogive/Commulative distribution plot" = fördelnings plot
- 3) "Boxplot" = lådagram
- 4) "Histogram"

Dessa kan ni läsa om i boken själva.

Det står även om följande saker till i kapitel 6:

- *) "Sample mean" = stickprovs medelvärde
- *) "Sample variance" = stickprovs varians

(som vi pratar om i kapitel 7 - vänta tills dess,
och)

*) median :

6.2

$x_1, \dots, x_n$ är ett datamaterial i (vanliga) siffror

$x_{(1)}, \dots, x_{(n)}$ är samma data ordnade i växande ordning

$$\text{medianen} = \tilde{X} = \begin{cases} x_{(k)} & \text{om } n = 2k-1 \text{ är udda} \\ (x_{(k)} + x_{(k+1)})/2 & \text{om } n = 2k \text{ är jämn} \end{cases}$$

är det mittersta värdet bland data

Kapitel 7: "Estimation" = skattning

$X_1, \dots, X_n$ oberoende (stokastiska variabler) med samma frekvensfunktion $f(x) = f_X(x)$ som en (stokastisk variabel) X

$X_1, \dots, X_n$ (kallas) stickprov på "sample" observationer av X

(frekvensfunktionen) f beror på en parameter θ (som kan vara en- eller flerdimensionell) vars värde vi ej vet

vi önskar skatta θ 's värde mha $X_1, \dots, X_n$


vår skattning $\hat{\theta}$ av θ är en funktion $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$ av stickprovet (vår tillgängliga information)

eftersom $X_1, \dots, X_n$ är stokastiska är $\hat{\theta}(X_1, \dots, X_n)$ stokastisk


Definition skattningen $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$ av parametern θ (med okänt värde) är väntevärdesriktig (vvr) om

$$E(\hat{\theta}) = E(\hat{\theta}(X_1, \dots, X_n)) = \theta$$

Eftersom $\hat{\theta}$ är en stokastisk variabel har den en frekvensfunktion



Om $\hat{\theta}$ är vvr är en liten varians $\text{Var}(\hat{\theta})$ för $\hat{\theta}$ önskvärd ty det betyder $\hat{\theta} \approx \theta$ med stor sannolikhet



Så har man två olika vvr skattningar av $\hat{\theta}$ är den med minst varians bäst.

Definition stickprovs medelvärde är

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

Sats $\bar{X}$ är en vvr skattning av $\mu = E(X_1) = \dots = E(X_n)$.

Bevis: $E(\bar{X}) = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{1}{n} \sum_{i=1}^n \mu = \mu. \square$
 ↗ sats 5.9

Sats $\text{Var}(\bar{X}) = \sigma^2/n$ då $\sigma^2 = \text{Var}(X_1) = \dots = \text{Var}(X_n)$

Bevis: $\text{Var}(\bar{X}) = \text{Var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_i) = \frac{1}{n^2} \sum_{i=1}^n \sigma^2 = \frac{\sigma^2}{n}. \square$
 ↗ 3 i sats 5.13

Definition stickprovsvariansen är

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

stickprovsstandardavvikelsen är $S = \sqrt{S^2}$

Sats S^2 är en vvr skattning av σ^2

(Beviset är småsvår övertkurs.)

(Det finns två allmänt användbara metoder för att hitta skattningar av parametrar:)

1) Momentmetoden

nu endimensionella
De parametrarna $\theta_1, \dots, \theta_l$ önskas skattade.

Frekvensfunktionen $f_X(x)$ för X (och $X_1, \dots, X_n$) är känd förutom den beror på okända $\theta_1, \dots, \theta_l$

a) använd $f_X(x)$ till räkna ut momenten

$$E(X^k) = m_k = m_k(\theta_1, \dots, \theta_l) = \int_{-\infty}^{+\infty} x^k f_X(x) dx$$

för $k=1, \dots, l$

b) räkna ut motsvarande stickprovsmoment

$$M_k = \frac{1}{n} \sum_{i=1}^n X_i^k \quad \text{för } k=1, \dots, l$$

c) finn lösningen $(\theta_1, \dots, \theta_l) = (\hat{\theta}_1, \dots, \hat{\theta}_l)$ till ekvationssystemet

$$\begin{cases} M_1 = m_1(\theta_1, \dots, \theta_l) \\ \vdots \\ M_l = m_l(\theta_1, \dots, \theta_l) \end{cases}$$

(Lösningen till ekvationssystemet är sökta skattningen.)

Exempel (Normalfördelning)

7.5

$X_1, \dots, X_n$ är observationer av X som är $N(\mu, \sigma^2)$

$$\begin{cases} m_1(\mu, \sigma^2) = E(X) = \mu \end{cases}$$

$$\begin{cases} m_2(\mu, \sigma^2) = E(X^2) = \text{Var}(X) + (E(X))^2 = \sigma^2 + \mu^2 \end{cases}$$

$$\text{Lös} \begin{cases} \mu = m_1(\mu, \sigma^2) = \bar{X} \\ \sigma^2 + \mu^2 = m_2(\mu, \sigma^2) = \frac{1}{n} \sum_{i=1}^n X_i^2 \end{cases}$$

Lösningen $(\mu, \sigma^2) = (\hat{\mu}, \hat{\sigma}^2)$ till detta är skattningen

$$\hat{\mu} = \bar{X}, \quad \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \hat{\mu}^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2$$

2) Maximum likelihood (ML) metoden

(Det är tryckfel mitt på sidan 232 i boken - där skall det stå ML metoden istf momentmetoden fetsstilt.)

$f_{\mathbf{X}}(\mathbf{x}) = f_{\mathbf{X}}(\mathbf{x}; \theta_1, \dots, \theta_e)$ beror av parameterarna (med okänt värde som önskas skattade)

a) bilda likelihoodfunktionen

$$L(\mathbf{X}_1, \dots, \mathbf{X}_n; \theta_1, \dots, \theta_e) = \prod_{i=1}^n f_{\mathbf{X}}(\mathbf{x}_i; \theta_1, \dots, \theta_e)$$

(produkttecken - som summa men gånger istället)

b) finn de värde $(\theta_1, \dots, \theta_e) = (\hat{\theta}_1, \dots, \hat{\theta}_e)$ som maximerar $L(\mathbf{X}_1, \dots, \mathbf{X}_n; \theta_1, \dots, \theta_e)$

(Lösningen till detta är skattningen.
Därav namnet maximum likelihood metoden.)

(Momentmetoden och ML-metoden för finna skattningar av parametrar behöver ej ge exakt samma skattningar men för det mesta är de åtminstone nästa lika.)

Man väljer ofta maximera
loglikelihooden $\ln(L(X_1, \dots, X_n; \theta_1, \dots, \theta_e))$
 istf likelihooden $L(X_1, \dots, X_n; \theta_1, \dots, \theta_e)$
 själv map $\theta_1, \dots, \theta_e$.

(Kom ihåg att det är inte maximala
 värdet av L eller $\ln L$ vi söker
 utan de parametrar $(\theta_1, \dots, \theta_e) = (\hat{\theta}_1, \dots, \hat{\theta}_e)$
 för vilket maximala värdet antages
 och de är samma för båda.)

Orsaken till maximera $\ln L$ istf L är att

$$\ln(L) = \ln\left(\prod_{i=1}^n f_{\mathbf{X}}(\mathbf{x}_i; \theta_1, \dots, \theta_e)\right) = \sum_{i=1}^n \ln(f_{\mathbf{X}}(\mathbf{x}_i; \theta_1, \dots, \theta_e))$$

omvandlar produkten till ofta enklare summa

Exempel (Normalfördelning fortsättning)

$X_1, \dots, X_n$ är observationer av X som är $N(\mu, \sigma^2)$

$$L = L(X_1, \dots, X_n; \mu, \sigma^2) = \prod_{i=1}^n f_X(X_i; \mu, \sigma^2) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(X_i - \mu)^2}{2\sigma^2}}$$

$$\ln(L) = -\frac{n}{2} \ln(2\pi) - n \ln(\sigma) - \sum_{i=1}^n \frac{(X_i - \mu)^2}{2\sigma^2}$$

$$\left\{ \begin{array}{l} \frac{\partial \ln(L)}{\partial \mu} = \sum_{i=1}^n \frac{(X_i - \mu)}{\sigma^2} = 0 \\ \frac{\partial \ln L}{\partial \sigma} = -\frac{n}{\sigma} + \sum_{i=1}^n \frac{(X_i - \mu)^2}{\sigma^3} = 0 \end{array} \right. \quad \text{har lösning}$$

$$(\mu, \sigma^2) = (\hat{\mu}, \hat{\sigma}^2) = \left(\frac{1}{n} \sum_{i=1}^n X_i, \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2 \right) = \left(\bar{X}, \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \right)$$

Konfidensintervall

7.9

(Bara) en skattning $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$ av en (okänd) parameter θ kan vara otillräcklig (då man ej vet något om skattningens precision).

Definition $[L_1(X_1, \dots, X_n), L_2(X_1, \dots, X_n)]$ kallas

ett konfidensintervall för θ med konfidensgrad $1 - \alpha \in (0, 1)$ om

$$P(L_1(X_1, \dots, X_n) \leq \theta \leq L_2(X_1, \dots, X_n)) = 1 - \alpha$$

Talet α väljes ofta som $\alpha = 0.05, 0.01$ eller 0.001 .

(För att lära er göra konfidensintervall för normalfördelade data - exemplet vi studerat två gånger - gör jag nu några förberedelser:

Sats Om $X_1, \dots, X_n$ är oberoende $N(\mu, \sigma^2)$ -fördelade är

$$\sum_{i=1}^n X_i \quad N(n\mu, n\sigma^2)\text{-fördelad.}$$

Bevis Jag använder MGF (momentgenererande funktion): kom ihåg att enligt exempel 4.3

$$m_{X_i}(t) = E(e^{tX_i}) = e^{\mu t + \frac{1}{2}\sigma^2 t^2}$$

så att eftersom $e^{tX_1}, \dots, e^{tX_n}$ (också) är oberoende (och därför okorrelerade)

$$\begin{aligned} m_{\sum_{i=1}^n X_i}(t) &= E(e^{t(X_1 + \dots + X_n)}) = E(e^{tX_1} \dots e^{tX_n}) \\ &= E(e^{tX_1}) \dots E(e^{tX_n}) = \left(e^{\mu t + \frac{1}{2}\sigma^2 t^2} \right)^n = e^{n\mu t + \frac{1}{2}n\sigma^2 t^2} \end{aligned}$$

som är MGF för $N(n\mu, n\sigma^2)$. $\square$

Följsats Om $X_1, \dots, X_n$ är oberoende $N(\mu, \sigma^2)$ -fördelade är

$\bar{X}$ $N(\mu, \sigma^2/n)$ -fördelad.

Bevis $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i = (X_1/n) + \dots + (X_n/n)$

där


$$m_{(X_i/n)}(t) = E(e^{t(X_i/n)}) = E(e^{(t/n)X_i}) = e^{ut/n + \frac{1}{2}\sigma^2 t^2/n^2}$$

är MGF för en $N(\mu/n, \sigma^2/n^2)$ -fördelning
så att genom byta ut μ och σ^2 mot
 μ/n och σ^2/n^2 i föregående sats

$$\bar{X} = (X_1/n) + \dots + (X_n/n) \text{ är } N(\mu, \sigma^2/n)\text{-fördelad. } \square$$

Exempel (Normalfördelning fortsättning)

$X_1, \dots, X_n$ är observationer av X som är $N(\mu, \sigma^2)$



$\alpha/2, 1-\alpha, \alpha/2$ är areor

talet $\lambda_{\alpha/2}$ finnes mha tabell V

Om $\alpha=0.01$ är $P(N(0,1) \leq \lambda_{\alpha/2}) = 1 - \alpha/2 = 0.995$
vilket enligt tabell V ger $\lambda_{\alpha/2} = 2.575$

$$P\left(\bar{X} - \lambda_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + \lambda_{\alpha/2} \frac{\sigma}{\sqrt{n}}\right) = 1 - \alpha$$

är konfidensintervall för μ med konfidensgrad $1-\alpha$ eftersom händelsen (vi räknar P för) ovan är samma som

$$\left\{ -\lambda_{\alpha/2} \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq \lambda_{\alpha/2} \right\}$$

där $(\bar{X} - \mu)/(\sigma/\sqrt{n})$ är $N(0,1)$ enligt föregående sats och sats 4.12.

Konfidensintervallet för μ ovan skrivs ofta kortare

$$\mu \in \bar{X} \pm \lambda_{\alpha/2} \sigma / \sqrt{n} \text{ med sannolikhet } 1-\alpha$$

och fungerar då σ är känt.

Fråga: Vad gör man då σ okänt (=realistiskt)?

Svar: Ersätt σ med S (dvs roten av stickprovsvariansen)!

(Det är en allmän princip i statistik att om man behöver ett parametervärde som man ej vet så ersätter man det med ett skattat parametervärde.)

Då σ ersättes med S får konfidensintervallet approximativ konfidensgrad $1-\alpha$ istf exakt (eftersom vi ändrat från vår exakta beräkning).

Kom ihåg sats 4.13 enligt vilken

$$\sum_{i=1}^n (X_i - \mu) / \sqrt{n\sigma^2} = (\bar{X} - \mu) / \sqrt{\sigma^2/n} \approx N(0,1)$$

För vilka som helst oberoende likafördelade $X_1, \dots, X_n$ med väntevärde μ och varians σ^2 .

Eftersom detta var precis den information vi utnyttjade i exemplet ovan men med (approximativ likhet) $\approx$ utbytt mot (likhet) = följer att

$$\mu \in \bar{X} \pm \lambda_{\alpha/2} \sigma / \sqrt{n} \approx \bar{X} \pm \lambda_{\alpha/2} S / \sqrt{n}$$

är konfidensintervall för μ med approximativ konfidensgrad $1 - \alpha$ för alla $X_1, \dots, X_n$ som ovan!

(Detta är ett av de mest grundläggande och mest använda faktumen i statistik.)

Exempel (Binomial approximation)

Om $X_1, \dots, X_n$ är oberoende likafördelade Binomial $(1, p)$ (dvs var och en av dem är 1 eller 0 med sannolikhet p respektive $1-p$) är

$$Y = X_1 + \dots + X_n \text{ Binomial } (n, p)\text{-fördelad}$$

(se text efter Definition 3.14 - ty Y är antalet lyckade försök av n utförda försök då varje försök lyckas med sannolikhet p).

Eftersom $E(X_i) = p$ och $\text{Var}(X_i) = p(1-p)$ (se exempel 3.2) så att enligt föregående teori är

$$\left\{ \begin{aligned} &(\bar{Y} - np) / \sqrt{np(1-p)} = \sum_{i=1}^n (X_i - p) / \sqrt{np(1-p)} \approx N(0, 1) \\ &p \in \bar{X} \pm \lambda_{\alpha/2} \frac{\sigma}{\sqrt{n}} = \bar{X} \pm \lambda_{\alpha/2} \sqrt{p(1-p)/n} \end{aligned} \right.$$

med konfidensgrad $\approx 1 - \alpha$

där okända p på högersidan kan ersättas av skattningen $\hat{p} = \hat{u} = \bar{X}$.