

SF1901: Sannolikhetslära och statistik

Föreläsning 9.

Statistik: Intervallskattning (konfidensintervall)

Jan Grandell & Timo Koski

21.02.2012



Idén med konfidensintervall

Det föreligger som vanligt ett slumpmässigt stickprov x_1, \dots, x_n från en fördelning som beror av den okända parametern θ (eventuellt flera stickprov från fördelningar som beror av θ).

En vag definition som strax skall preciseras: Ett intervall I_θ som med sannolikheten $1 - \alpha$ täcker över θ kallas ett *konfidensintervall* för θ med *konfidensgraden* $1 - \alpha$.



KONFIDENSINTERVALL

Definition

Låt x_1, x_2, \dots, x_n vara utfall av X_1, X_2, \dots, X_n vars fördelning beror av en okänd parameter θ . Intervallet

$$I_\theta = (a_1(x_1, \dots, x_n), a_2(x_1, \dots, x_n))$$

kallas ett konfidensintervall för θ med konfidensgrad $1 - \alpha$ om

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



KTH Matematik

- Konfidensintervall, definition, konfidensgrad
 - konfidensintervall för θ i $N(\theta, \sigma)$ med känt σ .
 - konfidensintervall för θ i $N(\theta, \sigma)$ med okänt σ .
 - konfidensintervall för σ^2 i $N(\theta, \sigma)$
- Nya sannolikhetsfördelningar dyker upp vid konfidensintervall
 - t-fördelning
 - $\chi^2(n)$ -fördelning
- Konfidensintervall med approximativ konfidensgrad
 - konfidensintervall för p i $Bin(p)$
 - konfidensintervall för θ i $Po(\theta)$



Exempel: Mätningar med fel



mätvärde = $\theta +$ slumpmässigt normalfördelat mätfel

$$X_i = \theta + \sigma Z_i, \quad Z_i \in N(0, 1), \quad i = 1, 2, \dots, n$$

- x_1, \dots, x_n , observerade utfall av $X_1 \in N(\theta, \sigma)$, ... $X_n \in N(\theta, \sigma)$, respektive.
- Vi vill ha en uppfattning om precisionen i skattningen. Visserligen vet vi att

$$E(\bar{X}) = \theta \quad \text{och} \quad D(\bar{X}) = \frac{\sigma}{\sqrt{n}},$$

men vi vill ha en mera informativ och lättbegriplig beskrivning → konfidensintervall.



Repetition: Kvantiler

α -kvantilen för $Z \in N(0, 1)$ λ_α definieras av

$P(Z > \lambda_\alpha) = \alpha$ eller

$$\alpha = 1 - \Phi(\lambda_\alpha).$$

Symmetri ger

$$\alpha = \Phi(\lambda_{1-\alpha})$$

\Leftrightarrow

$$\alpha = 1 - \Phi(-\lambda_{1-\alpha}),$$

vilket ger

$$\lambda_{1-\alpha} = -\lambda_\alpha.$$

(Slut på repetition.)



$N(\theta, \sigma)$, konfidensintervall för θ fall a) σ känt

Vi antar att X_1, X_2, \dots, X_n är oberoende och $N(\theta, \sigma)$ -fördelade.
Detta innebär att

$$\frac{\bar{X} - \theta}{\sigma / \sqrt{n}}$$
 är $N(0, 1)$ -fördelad.

Således gäller att

$$P\left(-\lambda_{\alpha/2} < \frac{\bar{X} - \theta}{\sigma / \sqrt{n}} < \lambda_{\alpha/2}\right) = 1 - \alpha.$$

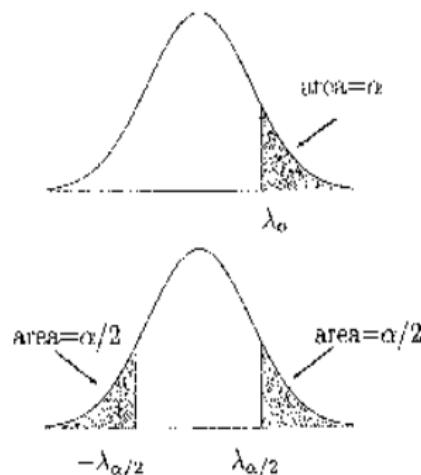


Kursens formelsamling: kvantiler för $N(0,1)$

Tab 2. Normalfördelningens kvantiler

$P(X > \lambda_\alpha) = \alpha$ därför $X \in N(0,1)$

α	λ_α	α	λ_α
0.10	1.2816	0.001	3.0902
0.05	1.6449	0.0005	3.2905
0.025	1.9600	0.0001	3.7190
0.010	2.3263	0.00005	3.8906
0.005	2.5758	0.00001	4.2649



$N(\theta, \sigma)$, konfidensintervall för θ a) σ känt

Detta ger

$$P\left(-\lambda_{\alpha/2} < \frac{\bar{X} - \theta}{\sigma/\sqrt{n}} < \lambda_{\alpha/2}\right) = 1 - \alpha.$$

\Updownarrow

$$P\left(-\lambda_{\alpha/2}\sigma/\sqrt{n} < \bar{X} - \theta < \lambda_{\alpha/2}\sigma/\sqrt{n}\right) = 1 - \alpha$$

\Updownarrow



$N(\theta, \sigma)$, konfidensintervall för θ fall a) σ känt

$$P\left(-\lambda_{\alpha/2}\sigma/\sqrt{n} < \theta - \bar{X} < \lambda_{\alpha/2}\sigma/\sqrt{n}\right) = 1 - \alpha$$

\Updownarrow

$$P\left(\bar{X} - \lambda_{\alpha/2}\sigma/\sqrt{n} < \theta < \bar{X} + \lambda_{\alpha/2}\sigma/\sqrt{n}\right) = 1 - \alpha.$$

Jmf. vi definitionen av konfidensintervall så inser vi att

$$\underline{I_\theta = \bar{x} \pm \lambda_{\alpha/2}\sigma/\sqrt{n}}$$

har konfidensgrad $1 - \alpha$. En vanlig konfidensgrad är 95%. Då är $\lambda_{0.025} = 1.96$.



$N(\theta, \sigma)$, konfidensintervall för θ . Fall a) σ känt

$$\underline{I_\theta = \bar{x} \pm \lambda_{\alpha/2} \sigma / \sqrt{n}}$$

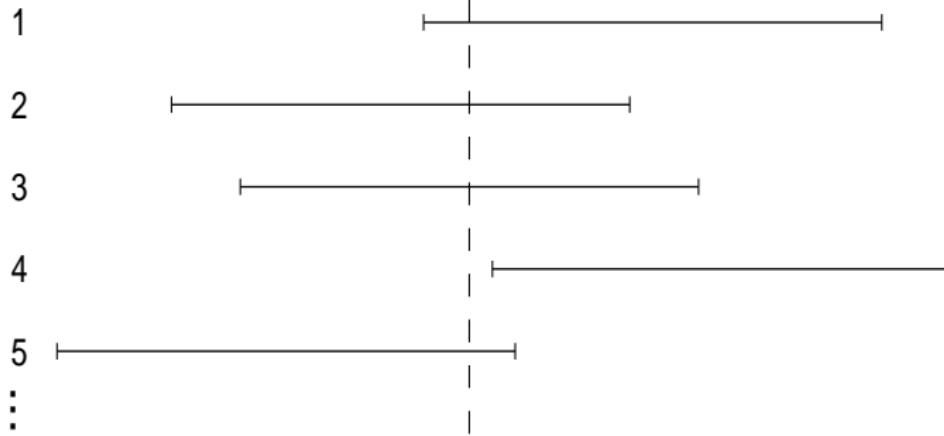
Intervallängden beror som synes av σ . Ju större precision mätningen har, desto mindre är σ och desto kortare blir intervallet. Längden är också beroende av den önskade konfidensgraden. Med 95 % konfidensgrad blir konstanten $\lambda_{\alpha/2} = 1.96$, 99 % konfidensgrad ger $\lambda_{\alpha/2} = 2.58$, och intervallet är ca 30 % längre.

$N(\theta, \sigma)$, konfidensintervall för θ a) σ känt

Låt oss gång på gång upprepa insamlingen av data och varje gång bestämma ett tvåsidigt 95 % intervall. I det långa loppet skulle 95% av dem täcka över det okända värdet θ , medan återstoden skulle "missa" det.

Mätning nr

θ



$N(\theta, \sigma)$, konfidensintervall för θ . Fall b) σ okänt

Vi utgår nu från

$$\frac{\bar{X} - \theta}{S/\sqrt{n}},$$

där

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

Man kan bestämma fördelningen för $\frac{\bar{X} - \theta}{S/\sqrt{n}}$.



$N(\theta, \sigma)$, konfidensintervall för θ . Fall b) σ okänt

Det gäller att

$$\frac{\bar{X} - \theta}{S/\sqrt{n}}$$

är t -fördelad med $n - 1$ frihetsgrader, eller att den är $t(n - 1)$ -fördelad.
Vi återkommer till t -fördelningens matematik senare i denna föreläsning.



Tätheten för $t(n)$

$t(n)$ -fördelningen kallas även Students t -fördelning. $n = 1, 2, 3, \dots$

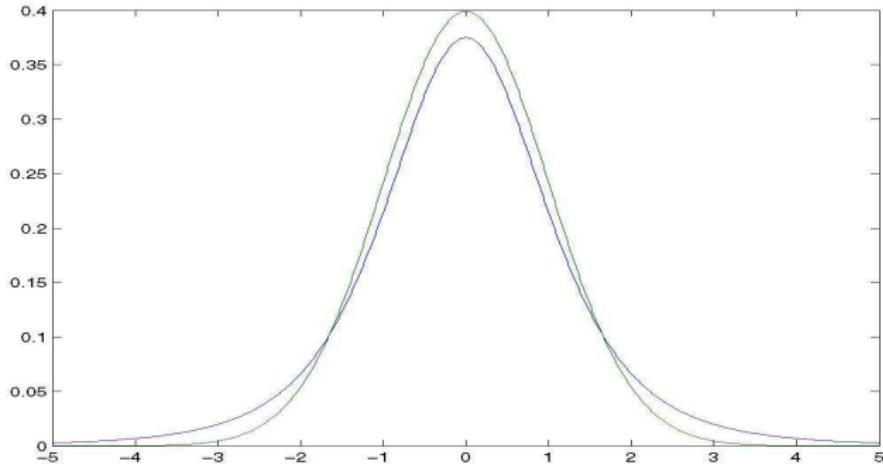
$$f_X(x) = \frac{\Gamma((n+1)/2)}{\sqrt{\pi n} \Gamma(n/2)} \left(1 + \frac{x^2}{n}\right)^{-(n+1)/2}$$

Vi kommer att använda t -fördelningens kvantiler men inte alls med denna formel. $\Gamma(x)$ finns definierad på sid. 64 av G. Blom m.fl..



Kursens formelsamling: kvantiler för $t(n)$

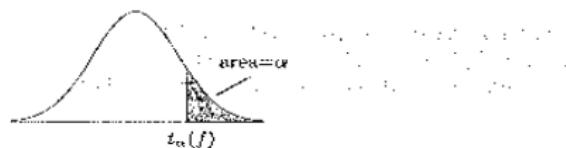
Fördelning är symmetrisk, och för stora värden på n , lik $N(0,1)$ -fördelningen. I bilden ser vi $t(4)$ (funktionsgraf i blått) och $N(0,1)$ (funktionsgraf i grönt).



Kursens formelsamling: kvantiler för $t(n)$

I tabellen är antalet frihetsgrader betecknat med f

Tabell 3. t -fördelningen.
 $P(X > t_\alpha(f)) = \alpha$, där $X \in t(f)$.



f	α	0.10	0.05	0.025	0.01	0.005	0.001	0.0005
1		3.08	6.31	12.71	31.82	63.66	318.31	636.62
2		1.89	2.92	4.30	6.96	9.92	22.33	31.60
3		1.64	2.35	3.18	4.54	5.84	10.21	12.92
4		1.53	2.13	2.78	3.75	4.60	7.17	8.61
5		1.48	2.02	2.57	3.36	4.03	5.89	6.87
6		1.44	1.94	2.45	3.14	3.71	5.21	5.96
7		1.41	1.89	2.36	3.00	3.50	4.79	5.41
8		1.40	1.86	2.31	2.90	3.36	4.50	5.04
9		1.38	1.83	2.26	2.82	3.25	4.30	4.78
10		1.37	1.81	2.23	2.76	3.17	4.14	4.59



$N(\theta, \sigma)$, konfidensintervall för θ b) σ okänt

På samma sätt som i a) fås nu att

$$\underline{I_\theta = \bar{x} \pm t_{\alpha/2}(n-1)s/\sqrt{n}}$$

är ett konfidensintervall för θ med konfidensgrad $1 - \alpha$.

I fallet med $n = 10$ gäller $t_{0.025}(9) = 2.26$, vilket kan jämföras med $\lambda_{0.025} = 1.96$.



Sammanfattning

Sats

Låt x_1, \dots, x_n vara ett slumpmässigt stickprov från $N(\theta, \sigma)$ där θ är okänt.
Då är

$$I_\theta = (\bar{x} - \lambda_{\alpha/2} D, \bar{x} + \lambda_{\alpha/2} D)$$

om σ är känt ($D = \sigma / \sqrt{n}$)

samt

$$I_\theta = (\bar{x} - t_{\alpha/2}(f) d, \bar{x} + t_{\alpha/2}(f) d)$$

om σ är okänt ($d = s / \sqrt{n}$, $f = n - 1$)

ett tvåsidigt konfidensintervall för θ med konfidensgraden $1 - \alpha$.





The derivation of the t-distribution was first published in 1908 by William Sealy Gosset, while he worked at a Guinness Brewery in Dublin. He was prohibited from publishing under his own name, so the paper was written under the pseudonym Student.



$\chi^2(n)$ -fördelning

Vi ska börja med ett par sannolikhetsteoretiska resultat.

Sats

Om Z_1, \dots, Z_n är oberoende och $N(0, 1)$ -fördelade, så är

$$\sum_{i=1}^n Z_i^2$$

$\chi^2(n)$ -fördelad (uttal: tji-två eller ki-två) med n frihetsgrader.



$\chi^2(n)$ -fördelning: täthet

Definition

Om den s.v. X har täthetsfunktionen

$$f_X(x) = \begin{cases} \frac{x^{f/2-1} e^{-x/2}}{\Gamma(f/2) 2^{f/2}} & \text{om } x > 0 \\ 0 & \text{om } x \leq 0, \end{cases}$$

säges X vara χ^2 -fördelad med f frihetsgrader.

Vi använder kvantilerna för $\chi^2(n)$ -fördelning men inte alls formeln för täheten. $\Gamma(f/2)$ finns definierad på sid. 64 av G. Blom .fl..



$\chi^2(n)$ -fördelning

$X \in \chi^2(n)$.

$$P(X \geq \chi_{\alpha/2}^2(n)) = \frac{\alpha}{2}$$

$$P(X \geq \chi_{1-\alpha/2}^2(n)) = 1 - \frac{\alpha}{2}$$

Vi är nu i en lite besvärligare situation än för μ , eftersom χ^2 -fördelningen inte är symmetrisk. I normal- respektive t -fallet utnyttjade vi att symmetrin medförde att $\lambda_{1-\alpha} = -\lambda_\alpha$ resp. $t_{1-\alpha}(n-1) = -t_\alpha(n-1)$.



Kursens formelsamling: kvantiler för $\chi^2(n)$ -fördelning

Tabell 4. χ^2 -fördelningen.

$P(X > \chi_{\alpha}^2(f)) = \alpha$, där $X \in \chi^2(f)$.



f	α	0.9995	0.999	0.995	0.99	0.975	0.95	0.05	0.025	0.01	0.005	0.001	0.0005
1		0.00	0.00	0.00	0.00	0.00	0.00	3.84	5.02	6.63	7.88	10.8	12.1
2		0.00	0.00	0.01	0.02	0.05	0.10	5.99	7.38	9.21	10.6	13.8	15.2
3		0.02	0.02	0.07	0.11	0.22	0.35	7.81	9.35	11.3	12.8	16.3	17.7
4		0.06	0.09	0.21	0.30	0.48	0.71	9.49	11.1	13.3	14.9	18.5	20.0
5		0.16	0.21	0.41	0.55	0.83	1.15	11.1	12.8	15.1	16.7	20.5	22.1
6		0.30	0.38	0.68	0.87	1.24	1.64	12.6	14.4	16.8	18.5	22.5	24.1
7		0.48	0.60	0.99	1.24	1.69	2.17	14.1	16.0	18.5	20.3	24.3	26.0
8		0.71	0.86	1.34	1.65	2.18	2.73	15.5	17.5	20.1	22.0	26.1	27.9



$\chi^2(n)$ -fördelning

Sats

Om X_1, X_2, \dots, X_n är oberoende och $N(\theta, \sigma)$ -fördelade så är

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

$\chi^2(n-1)$ -fördelad.

Detta är den "riktiga" motiveringen till att man i s^2 dividerar med $n-1$.



konfidensintervall för σ^2 i $N(\theta, \sigma)$

Vi kommer att använda $\frac{(n-1)S^2}{\sigma^2}$ för konfidensintervall lite på samma sätt som vi använde oss av \bar{X} för konfidensintervall för θ .

Konfidensintervall för σ^2

Låt nu $\chi_{\alpha}^2(n - 1)$ vara α -kvantilen i $\chi^2(n - 1)$ -fördelningen. Då gäller

$$P\left(\chi_{1-\alpha/2}^2(n - 1) < \frac{(n - 1)S^2}{\sigma^2} < \chi_{\alpha/2}^2(n - 1)\right) = 1 - \alpha$$

\Updownarrow

$$P\left(\frac{\chi_{1-\alpha/2}^2(n - 1)}{n - 1} < \frac{S^2}{\sigma^2} < \frac{\chi_{\alpha/2}^2(n - 1)}{n - 1}\right) = 1 - \alpha$$

\Updownarrow



Konfidensintervall för σ^2

$$P\left(\frac{n-1}{\chi_{\alpha/2}^2(n-1)} < \frac{\sigma^2}{S^2} < \frac{n-1}{\chi_{1-\alpha/2}^2(n-1)}\right) = 1 - \alpha$$

↔

$$P\left(\frac{(n-1)S^2}{\chi_{\alpha/2}^2(n-1)} < \sigma^2 < \frac{(n-1)S^2}{\chi_{1-\alpha/2}^2(n-1)}\right) = 1 - \alpha$$



Ett stickprov, konfidensintervall för σ^2

\Updownarrow

$$P\left(\sqrt{\frac{(n-1)S^2}{\chi_{\alpha/2}^2(n-1)}} < \sigma < \sqrt{\frac{(n-1)S^2}{\chi_{1-\alpha/2}^2(n-1)}}\right) = 1 - \alpha.$$

Ett stickprov, konfidensintervall för σ^2

Detta ger att

$$\underline{I_{\sigma^2} = \left(\frac{(n-1)s^2}{\chi_{\alpha/2}^2(n-1)}, \frac{(n-1)s^2}{\chi_{1-\alpha/2}^2(n-1)} \right)}$$

resp.

$$\underline{I_\sigma = \left(\sqrt{\frac{(n-1)s^2}{\chi_{\alpha/2}^2(n-1)}}, \sqrt{\frac{(n-1)s^2}{\chi_{1-\alpha/2}^2(n-1)}} \right)}$$

är konfidensintervall för σ^2 resp. σ med konfidensgrad $1 - \alpha$.



t-fördelningen

Vi återgår nu lite till *t-fördelningen*.

Sats

Om X är $N(0,1)$ -fördelad, Y är $\chi^2(f)$ -fördelad, och X och Y är oberoende, så är

$$\frac{X}{\sqrt{Y/f}}$$

$t(f)$ -fördelad.



Sats

Om X_1, X_2, \dots, X_n är oberoende och $N(\theta, \sigma)$ -fördelade så är \bar{X} och S^2 oberoende.

Denna sats karakteriseras normalfördelningen! Med detta avses att satsen inte är sann för någon annan fördelning.



t-fördelningen

Av detta följer nu att

$$\frac{\bar{X} - \theta}{S/\sqrt{n}} = \frac{\bar{X} - \theta}{\sigma/\sqrt{n}} / \sqrt{\frac{S^2}{\sigma^2}}$$

är $t(n-1)$ -fördelad.

$$\frac{\bar{X} - \theta}{\sigma/\sqrt{n}} / \sqrt{\frac{S^2}{\sigma^2}} = \frac{\bar{X} - \theta}{\sigma/\sqrt{n}} / \sqrt{\frac{\frac{(n-1)S^2}{\sigma^2}}{n-1}}$$

$\frac{\bar{X} - \theta}{\sigma/\sqrt{n}} \in N(0, 1)$, $\frac{(n-1)S^2}{\sigma^2} \in \chi^2(n-1)$ och oberoende.



Användning av normalapproximation, approximativ konfidensgrad

- Fördelningen beror av en okänd parameter θ .
- en punktskattning θ^* som är ungefär normalfördelad med väntevärdet θ och standardavvikelsen $D = D(\theta^*)$.
- Då gäller approximativt

$$\frac{\theta^* - \theta}{D} \in N(0, 1).$$



Medelfel för en skattning

Vi använder variansen $V(\theta^*)$ eller, vilket i princip är samma sak, standardavvikelsen $D(\theta^*)$ som precisionsmått för en skattning θ^* . Ju mindre varians (större effektivitet), desto belåtnare är vi med skattningen. Ibland hamnar man då i en besvärlig situation: Variansen och standardavvikelsen är själva okända, emedan de beror av just den parameter som man vill skatta (och kanske av ytterligare andra okända parametrar).



Medelfel för en skattning

Om man vill få information om $D(\theta^*)$ får man försöka hitta på en skattning även av denna storhet (parameter). Konsekvensen blir att man inte får ett exakt precisionsmått utan bara ett ungefärligt. Vi skulle kunna beteckna denna numeriska skattning av osäkerheten med $D(\theta^*)_{\text{obs}}^*$ men skriver den i stället $d(\theta^*)$.

Definition

En skattning av $D(\theta^)$ kallas medelfelet för θ^* och betecknas $d(\theta^*)$.*

Hur medelfelet skall väljas får avgöras från fall till fall. Man borde tillse att $d(\theta^*)$ är en konsistent skattning av $D(\theta^*)$.

Detta kan nog verka förbryllande men man skall hålla isär begreppen: θ^*_{obs} är en skattning av θ och $d(\theta^*)$ är en skattning av $D(\theta^*)$. Det var detta vi gjorde i det inledande exemplet i samband med analys av en opinionsundersökning.



KTH Matematik

Konfidensintervall med en approximativ konfidensgrad

En punktskattning θ^* av en okänd parameter θ är ungefär normalfördelad med väntevärdet θ och standardavvikelsen D . Då är

$$I_\theta = (\theta^* - \lambda_{\alpha/2}D, \theta^* + \lambda_{\alpha/2}D) \quad \text{om } D \text{ ej beror av } \theta$$
$$I_\theta = (\theta^* - \lambda_{\alpha/2}d, \theta^* + \lambda_{\alpha/2}d) \quad \text{om } D \text{ beror av } \theta$$

(och d väljs lämpligt) ett konfidensintervall för θ med den approximativa konfidensgraden $1 - \alpha$.



Konfidensintervall med en approximativ konfidensgrad

Låt x_1, \dots, x_n vara ett stort slumpmässigt stickprov från en fördelning, där väntevärdet är θ och standardavvikelsen σ . Då är

$$I_\mu = (\bar{x} - \lambda_{\alpha/2}D, \bar{x} + \lambda_{\alpha/2}D) \quad \text{om } \sigma \text{ känt } (D = \sigma/\sqrt{n})$$
$$I_\mu = (\bar{x} - \lambda_{\alpha/2}d, \bar{x} + \lambda_{\alpha/2}d) \quad \text{om } \sigma \text{ okänt } (d = s/\sqrt{n})$$

konfidensintervall för θ med den approximativa konfidensgraden $1 - \alpha$.



Konfidensintervall för p i $\text{Bin}(n, p)$ med en approximativ konfidensgrad

Låt x vara en observation av X , där $X \in \text{Bin}(n, p)$ och p är okänt.
Maximum-likelihood skattningen är

$$p_{\text{obs}}^* = x/n.$$

Man kan inte enkelt konstruera ett interval I_p som exakt har given konfidensgrad.



Konfidensintervall för p i $\text{Bin}(n, p)$ med en approximativ konfidensgrad

För stora n gäller approximativt att $X/n \in N(p, D)$ där $D = \sqrt{p(1-p)/n}$. Som medelfel tar vi $d = \sqrt{p_{\text{obs}}^*(1 - p_{\text{obs}}^*)/n}$. och får intervallet

$$I_p = (p_{\text{obs}}^* - \lambda_{\alpha/2} d, p_{\text{obs}}^* + \lambda_{\alpha/2} d) \quad (d = \sqrt{p_{\text{obs}}^*(1 - p_{\text{obs}}^*)/n}). \quad (1)$$

Konfidensintervall för p i $\text{Bin}(n, p)$ med en approximativ konfidensgrad

Vid intervjuer med $n = 250$ personer, uttagna slumpmässigt ur en mycket stor population, visade sig 42 ha en viss åsikt H . Som punktskattning av relativt antalet p i hela populationen med åsikten H tar vi $p_{\text{obs}}^* = 42/250 = 0.168$. Alltså blir

$$d = \sqrt{0.168 \cdot 0.832/250} = 0.023.$$

Ett approximativt 95 % konfidensintervall för p blir

$$I_p = (0.168 \pm 1.96 \cdot 0.023) = (0.168 \pm 0.046) = (0.12, 0.21).$$



Approximativa konfidensintervall

Man önskar planera undersökningen så, att man efteråt får ett ungefär 95 % konfidensintervall för p med högst längden $2 \cdot 0.05$. Hur många skall tillfrågas ?



Approximativa konfidensintervall

Man får

$$2 \cdot 1.96 \sqrt{\frac{p_{\text{obs}}^*(1 - p_{\text{obs}}^*)}{n}} < 2 \cdot 0.05$$

varav, eftersom alltid $p(1 - p) \leq 1/4$,

$$n \gtrsim \frac{1}{4} \left(\frac{1.96}{0.05} \right)^2 = 384.2.$$

385 personer bör alltså tillfrågas.



Approximativa konfidensintervall: populationsundersökning

ML-skattningen av p blir, som vi redan vet $p_{\text{obs}}^* = x/n$. Den approximativa formeln för konfidensintervallet blir

$$I_p = (p_{\text{obs}}^* - \lambda_{\alpha/2} d, p_{\text{obs}}^* + \lambda_{\alpha/2} d) \quad (d = d_n \sqrt{p_{\text{obs}}^*(1 - p_{\text{obs}}^*)/n}). \quad (2)$$

där $d_n = \sqrt{(N-n)/(N-1)}$ är en s.k. korrektionsfaktor för ändlig population.



Approximativa konfidensintervall: poissonfördelning

Vi har ett slumprässigt stickprov x av $X \in Po(\theta)$ och punktskattar μ .

Under antagande att det är känt att $\theta > ca 15$ kan
normalapproximationen användas

Som skattning av θ tar vi $\theta_{obs}^* = x$. Tillhörande standardavvikelse är
 $D(X) = \sqrt{\theta}$ och vi tar därför som medelfel $d = \sqrt{x}$.

Approximativa konfidensintervall: poissonfördelning

Konfidensintervallet för θ blir enligt den approximativa metoden

$$I_\theta = (x - \lambda_{\alpha/2}\sqrt{x}, x + \lambda_{\alpha/2}\sqrt{x}). \quad (3)$$

Dess konfidensgrad är ungefär $1 - \alpha$, och approximationen är bättre ju större θ är.

