

## Allmän metodik att härleda konfidensintervall

Vi har data  $x_1, x_2, \dots, x_n$  som vi ser som utfall av stokastiska variabler  $X_1, X_2, \dots, X_n$  vilkas fördelning påverkas av en parameter  $\Theta$ .

Ett konfidensintervall med konfidensgraden  $1 - \alpha$  (typiskt 95% dvs att  $\alpha = 0.05$ ) för parametern  $\Theta$  är ju ett numeriskt intervall

$$(a(x_1, x_2, \dots, x_n), b(x_1, x_2, \dots, x_n))$$

där funktionerna  $a$  respektive  $b$  skall välja så att

$$P(a(X_1, X_2, \dots, X_n) \leq \Theta \leq b(X_1, X_2, \dots, X_n)) = 1 - \alpha.$$

Detta betyder att det numeriska konfidensintervallet är att betrakta som ett utfall av det stokastiska intervallet

$$(a(X_1, X_2, \dots, X_n), b(X_1, X_2, \dots, X_n))$$

och konfidensgraden anger sannolikheten att det stokastiska intervallet innehåller  $\Theta$ . Konfidensgraden anger alltså sannolikheten att metoden att räkna ut konfidensintervallet fungerar, men är inte en utsaga om det enskilda numeriska konfidensintervallet.

Det finns en standardiserad metodik i 5 steg som (nästan) maskinmässigt tar fram funktionerna  $a$  och  $b$ , dvs som producerar konfidensintervall. Formelsamlingen utgör en rik källa av tips vad gäller det praktiska genomförande av dessa 5 steg. Dessutom finns hjälpresultat som genomför stegen 3-5 i ett svep. Nedan beskrivs dessa 5 steg först generellt och sen hur de praktiskt genomförs i 3 olika situationer.

1) Skatta  $\Theta$  med någon listigt vald punktskattning  $\Theta^*(x_1, x_2, \dots, x_n)$  som t ex tas fram med hjälp Maximum Likelihood-metoden eller Minsta Kvadratmetoden. I vissa situationer finns andra okända parametrar än  $\Theta$  och dessa skall också skattas.

2) Ta fram fördelningen för motsvarande stickprovsvariabel  $\Theta^*(X_1, X_2, \dots, X_n)$ . Här kan formelsamlingen vara till stor hjälp.

3) Gör en listig transformation av stickprovsvariabeln så att resultatet ej beror av  $\Theta$  eller andra parametrar som finns i problemet. Denna s k pivot-variabel (pivot betyder svängtapp - ett bra svenskt namn vore "grundbult") innehåller alltid den okända parametern  $\Theta$ . Formelsamlingen vimlar med tips om lämpliga transformationer i specifika situationer. I de konkreta situationer som beskrivs nedan ges exempel på dessa pivot-variabler. Vi skaffar oss alltså en ny variabel ur  $\Theta^*$  som vi kallar t ex  $T$  som har en fix (känd) fördelning oavsett värdet på  $\Theta$ .

4) Vi väljer tal  $c$  och  $d$  så att  $P(c \leq T \leq d) = 1 - \alpha$ . Detta innebär att vi skall hitta percentiler till fördelningen för  $T$ . Tabell 2-4 i formelsamlingen anger sådana s.k. percentiler för tre fördelningar som ofta dyker upp som fördelning för pivot-variabeln  $T$  nämligen  $N(0, 1)$ -fördelningen,  $t$ -fördelningen och  $\chi^2$ -fördelningen. Om vi tar  $c$  och  $d$  så att  $P(T < c) = P(T > d) = \alpha/2$  får vi tvåsidiga symmetriska konfidensintervall, som alltså ger både en undre och en övre gräns för parametern  $\Theta$ . Vill vi bara ha en undre eller bara en övre gräns för  $\Theta$  (s k enkelsidigt konfidensintervall) skall vi ta  $P(T < c) = \alpha$  och  $d = +\infty$  eller  $P(T > d) = \alpha$  och  $c = -\infty$ .

5) Vi vränger nu ovanstående uttryck för  $T$  ut och in så att vi får  $\Theta$  ensamt i mitten och att  $\Theta$  ej finns någon annanstans. Vi har därmed fått  $\Theta$  instängt mellan två stokastiska gränser och konfidensintervallet är utfallet av dessa gränser, dvs typografiskt byter man  $X$  mot  $x$ !

Exempel 1: Som exempel kan vi låta våra mätdata  $x_1, x_2, \dots, x_n$  vara utfall av  $X_1, X_2, \dots, X_n$  som är oberoende  $N(\Theta, \sigma_0)$  där  $\sigma_0$  är känd och vi vill göra ett konfidensintervall för  $\Theta$  med konfidensgrad  $1 - \alpha$ . Stegen ovan motsvarar följande:

- 1)  $\Theta^* = \bar{x} = (x_1 + x_2 + \dots + x_n)/n$
- 2)  $\bar{X} = (X_1 + X_2 + \dots + X_n)/n$  är  $N(\Theta, \sigma_0/\sqrt{n})$ .
- 3)  $T = \frac{\bar{X} - \Theta}{\sigma_0/\sqrt{n}}$  är  $N(0, 1)$
- 4) Vi har då p g a symmetrin i  $N(0, 1)$ -fördelningen som gör  $\lambda_{1-\alpha/2} = -\lambda_{\alpha/2}$  att

$$P\left(-\lambda_{\alpha/2} \leq T \leq \lambda_{\alpha/2}\right) = P\left(-\lambda_{\alpha/2} \leq \frac{\bar{X} - \Theta}{\sigma_0/\sqrt{n}} \leq \lambda_{\alpha/2}\right) = 1 - \alpha$$

- 5) Vi får

$$P\left(\bar{X} - \lambda_{\alpha/2} \frac{\sigma_0}{\sqrt{n}} \leq \Theta \leq \bar{X} + \lambda_{\alpha/2} \frac{\sigma_0}{\sqrt{n}}\right) = 1 - \alpha$$

som ger konfidensintervallet  $\bar{x} \pm \lambda_{\alpha/2} \frac{\sigma_0}{\sqrt{n}}$ . De enkelsidiga intervallen blir då  $\left(-\infty, \bar{x} + \lambda_{\alpha} \frac{\sigma_0}{\sqrt{n}}\right)$  respektive  $\left(\bar{x} - \lambda_{\alpha} \frac{\sigma_0}{\sqrt{n}}, \infty\right)$ .

Exempel 2: Om vi stället skulle ha  $X_1, X_2, \dots, X_n$  som är oberoende  $N(\Theta, \sigma)$  där både  $\Theta$  och  $\sigma$  är okända blir metodiken följande:

- 1) Vi skattar  $\Theta$  med  $\bar{x}$  och  $\sigma$  med  $s$  där  $s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$
- 2) Vi vet att  $\bar{X}$  är  $N(\Theta, \sigma/\sqrt{n})$  och formelsamlingen ger att  $\frac{(n-1)s^2}{\sigma^2}$  är  $\chi^2(n-1)$ . Dessutom kan man visa (och läsa i formelsamlingen) att (förvånande nog)  $\bar{X}$  och  $s^2$  är oberoende. Notera att  $s$  här är stickprovsvariabeln dvs  $s^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$  och ej det numeriska värdet  $s$  där  $s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$  som alltså räknas ut med våra observerade mätdata. När vi nedan tittar på utfallet av det stokastiska intervallet skall vi dock använda oss av det numeriska värdet!
- 3) Här ger formelsamlingen att  $T = \frac{\bar{X} - \Theta}{s/\sqrt{n}}$  är  $t(n-1)$ -fördelad.  $t(n-1)$ -fördelningen införs och studeras just därför att den är fördelning för denna pivot-variabel.
- 4) Tabell 3 i formelsamlingen ger då p g a symmetrin i  $t(n-1)$ -fördelningen som gör att  $t_{1-\alpha/2}(n-1) = -t_{\alpha/2}(n-1)$  att

$$P\left(-t_{\alpha/2}(n-1) \leq \frac{\bar{X} - \Theta}{s/\sqrt{n}} \leq t_{\alpha/2}(n-1)\right) = 1 - \alpha$$

- 5) Vi får

$$P\left(\bar{X} - t_{\alpha/2}(n-1) \frac{s}{\sqrt{n}} \leq \Theta \leq \bar{X} + t_{\alpha/2}(n-1) \frac{s}{\sqrt{n}}\right) = 1 - \alpha$$

som ger intervallet

$$\bar{x} \pm t_{\alpha/2}(n-1) \frac{s}{\sqrt{n}}$$

Exempel 3: Skulle vi i situationen i Exempel 2 vilja göra konfidensintervall för  $\sigma$  får vi samma i 1) och 2) som ovan.

3) Pivotvariabel angavs redan i steg 2 dvs  $\frac{(n-1)s^2}{\sigma^2}$  utgör pivot-variabel för  $s$ .

4) Tabell 4 ger nu att

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

5) Vi får här

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

som ger intervallet

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

för  $\sigma$ .

Detta schema kan nu genomföras för t ex två oberoende stickprov eller enkel linjär regression med små modifikationer på lämpliga ställen. För de sk approximativa metoderna väljer man som pivot-variabel en som är approximativt  $N(0, 1)$  oftast genom hänvisning till Centrala gränsvärdessatsen. Eftersom pivot-variabeln då bara är approximativt  $N(0, 1)$  blir konfidensgraden bara approximativt den avsedda  $1 - \alpha$ . Dessa konfidensintervall kallas därför approximativa eftersom säkerheten i metoden bara är approximativt  $1 - \alpha$ .

Man kan vidare notera att Formelsamlingens avsnitt om  $\lambda$ -metoden,  $t$ -metoden, approximativa metoden och  $\chi^2$ -metoden genomför steg 3, 4 och 5 i ett enda svep.