

Punktskattningar

När man gör en statistisk undersökning är man oftast speciellt intresserad av vissa parametrar hos den underliggande fördelningen/populationen.

Exempel på sådana parametrar är väntevärde, varians/standardavvikelse och proportion. Från stickprovet vill vi ta fram bra "gissningar" på de riktiga parametrarnas värden. Då ~~använden~~ oss av punktskattningar kan vi använda

Exempelvis så är medelvärdet $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ en punktskattare för väntevärdet μ , $s^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$...

Ex: Vi kastar tärning men vi vet inte vad väntevärdet, μ , är för ~~antalet punkter~~ ~~vi ser~~. Resultatet av tärningskastet. ($\mu = 3.5$)

Vi kastar tärningen 100 gånger och antecknar resultaten: $x_1 = 2, x_2 = 6, x_3 = 1, \dots, x_{100} = 4$.

Medelvärdet blir $\bar{x} = \frac{1}{100} \sum_{i=1}^{100} x_i = 3.58$.

Vår punktskattning för μ blir alltså 3.58.

Obs: Innan mätningarna är gjorda så har vi bara skattare, dvs ~~stora~~ slumpvariabler. Efter mätningarna har vi ~~stora~~ beräknat skattningar, dvs tal.

Så ~~skattningarna~~ ^{skattarna} är slumpmässiga och det är väldigt liten sannolikhet att skattningarna är exakt lika med parametern. Dvs, i exemplet ovan är det väldigt liten sannolikhet att $\bar{x} = 3.5$. **Plot!**

② Oftast vill man också analysera hur stor osäkerhet det finns i våra skattningar. **Plot!**
Vi tar då hjälp av intervallskattningar.

Intervallskattningar (Konfidensintervall)

När man gör konfidensintervall vill man ta fram två ~~punkter~~_{tal}: en övre gräns U (upper) och en undre gräns L (lower) för intervallet. Vi skriver då $[L, U]$.

Idé: Vi bestämmer oss i förväg för ett procenttal t ex 95%. Vi vill sedan skapa intervallet $[L, U]$ på ett sådant sätt att vi är 95% säkra på att den viktiga parametern täcks av intervallet.

Om det t . ex. är ett väntevärde μ vi vill göra ett konfidensintervall för så vill vi att

$$0.95 = P(\text{konfidensintervallet täcker } \mu) = P(L \leq \mu \leq U).$$

Observera att μ är fix (dvs icke slumpmässig) men okänd. Det är L och U som är slumpmässiga. **Plot!**

Procenttalet vi väljer (95% ovan) kallas för konfidensgrad och 0.05 ~~är~~ kallas då för signifikansnivå, och betecknas med α .

Konfidensintervall för ett väntevärde (kap 7.2)

(3)

känd varians


Så hur tar vi fram L och U om det är μ vi är intresserade av? Kom ihåg att stickprovsnedvärdet $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ är vår punktskattare (och "bästa gissning") för μ . Vad vet vi om \bar{X} ?

Första veckan lärde vi oss att om n är stort så gäller att $\bar{X} \approx N(\mu, \frac{\sigma^2}{n})$ (Centralt gränsvärdesresultat).

Vi använder oss därför av

$$L = \bar{X} - \frac{1.96\sigma}{\sqrt{n}}$$

$$U = \bar{X} + \frac{1.96\sigma}{\sqrt{n}}$$



Motivering: \bar{X} hamnar i intervallet om och endast om μ ~~hamnar~~ ^{täcks} av intervallet $[L, U]$.

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

Ex: Åter till färingsexemplet. Vårt medelvärde (punktskattning) var 3.58 och vi vet att $\sigma^2 = \frac{35}{12}$, $n=100$. Vårt observerade konfidensintervall blir då

$$l = \bar{x} - \frac{1.96\sigma}{\sqrt{n}} = 3.58 - 1.96 \cdot \frac{\sqrt{35/12}}{\sqrt{100}} = 3.2453$$

$$u = \bar{x} + \frac{1.96\sigma}{\sqrt{n}} = 3.58 + 1.96 \cdot \frac{\sqrt{35/12}}{\sqrt{100}} = 3.9147$$

OBS: Det framtagna (observerade) intervallet $[l, u]$ är inte slumpmässigt. Det är ett vanligt missförstånd att hävda

④ att μ ligger i $[l, u]$ med 95% sannolikhet. Detta är en feltolkning eftersom varken μ , l eller u är slumpmässiga. Den korrekta tolkningen är: om vi upprepar proceduren ett stort antal gånger så kommer intervallet $[l, u]$ att innehålla μ ungefär 95% av gångerna. Man kan även säga att $[l, u]$ täcker μ med 95% säkerhet.

Resonemangen hittills bygger på att \bar{X} är normalfördelad. Detta stämmer om stickprovet X_1, \dots, X_n kommer från en normalfördelning och/eller n är tillräckligt stort. / slut

Hittills har vi använt signifikansnivå $\alpha = 0.05$ men det går bra att använda andra signifikansnivåer också.

Man förknippar ofta ett "z-värde" med signifikansnivån.


Värdet z_α definieras som det värde så att $P(Z > z_\alpha) = \alpha$ där $Z \sim N(0, 1)$.

Vi har t.ex. att

$z_{0.025} = 1.96$, det

är därför 1.96 dyker upp i

härledningarna tidigare.




Konfidensgrad $100(1-\alpha)\%$	Signifikansnivå α	$\alpha/2$	$z_{\alpha/2}$
90%	0.1	0.05	1.645
95%	0.05	0.025	1.96
99%	0.01	0.005	2.575

Ex: Tävningsexemplet igen, denna gång med signifikansnivå $\alpha = 0.1$. Vi får då

$$l = \bar{x} - \frac{1.645\sigma}{\sqrt{n}} = 3.58 - 1.645 \cdot \frac{\sqrt{35/12}}{\sqrt{100}} = 3.2991$$

$$u = \bar{x} + \frac{1.645\sigma}{\sqrt{n}} = 3.58 + 1.645 \cdot \frac{\sqrt{35/12}}{\sqrt{100}} = 3.8609$$



Generellt sätt skriver vi: $L = \bar{x} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}$, $U = \bar{x} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}$
 Generellt sätt: Alltså, ju lägre signifikansnivå (i.e. högre konfidensgrad) desto säkrare är vi på att intervallet täcker μ men intervallet blir då större, dvs mindre informativt.

Tabell 2 ger oss ~~alla~~ z-värden för några olika α .
 Men hur gör vi med ~~ganska~~ ^{andra} värden på α ?
~~Exempel~~ Det finns tänk på konstanten med mer fullständiga tabeller.

$$\alpha = 0.05 \Rightarrow \frac{1-\alpha}{2} = \frac{0.95}{2} = 0.475$$

$$\Rightarrow z_{\alpha/2} = 1.96$$

$$\alpha = 0.1 \Rightarrow \dots \Rightarrow z_{\alpha/2} = 1.645$$

