

En egenskap hos normalfördelningen


För en $N(\mu, \sigma^2)$ -fördelad variabel X gäller att

$$\rightarrow 1) P(\mu - \sigma < X < \mu + \sigma) \approx 0.68$$

$$2) P(\mu - 2\sigma < X < \mu + 2\sigma) \approx 0.95$$

$$3) P(\mu - 3\sigma < X < \mu + 3\sigma) \approx \text{~~0.99~~ } 0.997$$

Det innebär att om vi har ett stickprov från en $N(\mu, \sigma^2)$ -fördelning, så kommer ca 68% av observationerna att hamna i intervallet $[\mu - \sigma, \mu + \sigma]$, ungefär 95% i intervallet $[\mu - 2\sigma, \mu + 2\sigma]$ och ungefär 99.7% i intervallet $[\mu - 3\sigma, \mu + 3\sigma]$.



Centrala gränsvärdesatsen (Central limit theorem).

I vissa fall vet vi mer om \bar{X} än bara dess väntevärde och varians.

Sats: Om X_1, X_2, \dots, X_n är ett stickprov från en ~~normalfördelning~~ $N(\mu, \sigma^2)$ -fördelning så gäller att $\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$

Den här satsen kommer till användning snart. En annan mer användbar sats är följande

Sats (Centrala gränsvärdesatsen) (CGS)

Om X_1, X_2, \dots, X_n är ett stickprov från någon fördelning (vilken som helst!) med ~~ett~~ väntevärde μ och varians σ^2 så gäller att

$$\bar{X} \approx N\left(\mu, \frac{\sigma^2}{n}\right)$$

↑
approximativt

Ju större n desto bättre approximation.

CGS är ~~det~~ absolut viktigaste resultatet inom statistik. Om n är stort så är datans ursprung (nästan) irrelevant!

PLOT! (Täring)

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 ~~parametrar~~_{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 riktiga parametern täcks av intervallet.

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

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

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 .